

(19) 世界知的所有権機関
国際事務局(43) 国際公開日
2005年9月29日 (29.09.2005)

PCT

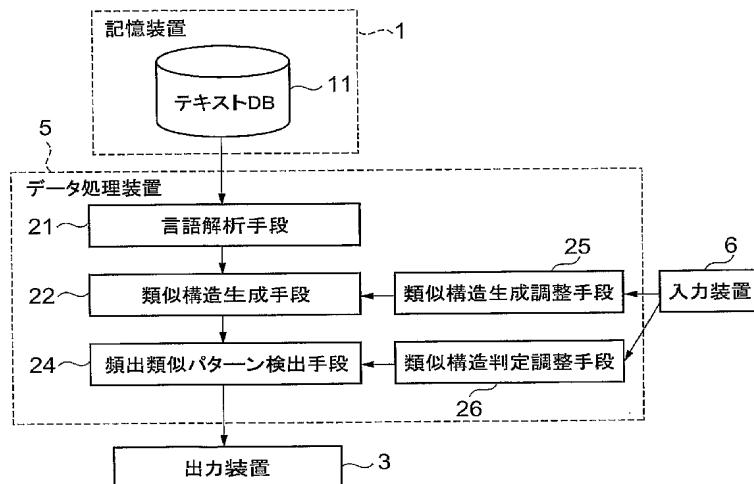
(10) 国際公開番号
WO 2005/091170 A1

(51) 国際特許分類⁷: G06F 17/30, 17/27, 19/00 (72) 発明者; および
 (21) 国際出願番号: PCT/JP2005/005440 (75) 発明者/出願人(米国についてのみ): 坂尾 要祐
 (22) 国際出願日: 2005年3月17日 (17.03.2005) (SAKAO, Yousuke) [JP/JP]; 〒1088001 東京都港区芝
 (25) 国際出願の言語: 日本語 五丁目7番1号 日本電気株式会社内 Tokyo (JP). 佐藤 研治 (SATOH, Kenji) [JP/JP]; 〒1088001 東京都港区
 (26) 国際公開の言語: 日本語 赤峯 享 (AKAMINE, Susumu) [JP/JP]; 〒1088001 東京都港区芝五丁目7番1号 日本電気株式会社内
 (30) 優先権データ: 特願2004-079077 2004年3月18日 (18.03.2004) JP (74) 代理人: 池田 嘉保, 外 (IKEDE, Noriyasu et al.); 〒1050003 東京都港区西新橋一丁目4番10号 第3森
 (71) 出願人(米国を除く全ての指定国について): 日本電気 (81) 指定国(表示のない限り、全ての種類の国内保護が
 株式会社 (NEC CORPORATION) [JP/JP]; 〒1088001 可能): AE, AG, AL, AM, AT, AU, AZ, BA, BB, BG, BR,
 東京都港区芝五丁目7番1号 Tokyo (JP). BW, BY, BZ, CA, CH, CN, CO, CR, CU, CZ, DE, DK, DM,

/ 続葉有 /

(54) Title: TEXT MINING DEVICE, METHOD THEREOF, AND PROGRAM

(54) 発明の名称: テキストマイニング装置、その方法及びプログラム



1 STORAGE DEVICE
 11 TEXT DB
 5 DATA PROCESSING DEVICE
 21 LANGUAGE ANALYSIS MEANS
 22 SIMILAR STRUCTURE GENERATION MEANS
 24 FREQUENCY SIMILAR PATTERN DETECTION MEANS
 25 SIMILAR STRUCTURE GENERATION ADJUSTMENT MEANS
 26 SIMILAR STRUCTURE JUDGMENT ADJUSTMENT MEANS
 6 INPUT DEVICE
 3 OUTPUT DEVICE

and outputs it to an output device (3).

(57) Abstract: Language analysis means (21) analyzes each of the texts read from a text DB (11) and generates a sentence structure as an analysis result. Similar structure generation adjustment means (25) generates a specification item for specifying whether the input from an input device has the same structure for each of the types of the sentence structure. Similar structure judgment adjustment means (26) generates a specification item whether to ignore the difference in value for each of the types of the attribute values according to the input from an input device (6). According to the specification item from the similar structure generation adjustment means (25), similar structure generation means (22) generates a similar structure of the partial structure constituting the sentence structure obtained by the language analysis means (21) and sets each of the similar structures generated as an equivalent value of the partial structure of each of the elements generated. According to the specification item given from the similar structure judgment adjustment means (26), frequent similar pattern detection means (24) ignores the attribute value, detects a frequent pattern from a set of the equivalent values from the similar structure generation means (22),

WO 2005/091170 A1

(57) 要約: 言語解析手段 21 はテキスト DB 11 から読み込んだ各テキストの解析を行い解析結果として文構造を生成する。類似構造生成調整手段 25 は入力装置からの入力より文

/ 続葉有 /



DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, HR, HU, ID, IL, IN, IS, JP, KE, KG, KP, KR, KZ, LC, LK, LR, LS, LT, LU, LV, MA, MD, MG, MK, MN, MW, MX, MZ, NA, NI, NO, NZ, OM, PG, PH, PL, PT, RO, RU, SC, SD, SE, SG, SK, SL, SM, SY, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, YU, ZA, ZM, ZW.

(84) 指定国(表示のない限り、全ての種類の広域保護が可能): ARIPO (BW, GH, GM, KE, LS, MW, MZ, NA, SD, SL, SZ, TZ, UG, ZM, ZW), ユーラシア (AM, AZ, BY, KG, KZ, MD, RU, TJ, TM), ヨーロッパ (AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HU,

IE, IS, IT, LT, LU, MC, NL, PL, PT, RO, SE, SI, SK, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, ML, MR, NE, SN, TD, TG).

添付公開書類:

- 國際調査報告書
- 補正書

2文字コード及び他の略語については、定期発行される各PCTガゼットの巻頭に掲載されている「コードと略語のガイダンスノート」を参照。

明 紹 書

テキストマイニング装置、その方法及びプログラム

技術分野

本発明は、構文解析などを用いて、コンピュータ上に蓄積される電子化テキストを構造化して分析を行うテキストマイニング装置、テキストマイニング方法及びテキストマイニング用プログラムに関し、特に、意味の類似した文の構造を同一の構造と判定して分析を行うことができるテキストマイニング装置、テキストマイニング方法及びテキストマイニング用プログラムに関する。

背景技術

テキストマイニング装置の一例として、図1に示すような構成が知られている（特許文献：特開2001-84250号公報（第4、5頁、第3図）参照）。図1に示すように、この従来のテキストマイニング装置は、基本辞書記憶部と、文書データ記憶部と、分野依存辞書記憶部と、言語特徴分析装置と、言語解析装置と、パターン抽出装置と、頻出パターン表示装置とを備えている。

図1に示した従来のテキストマイニング装置は、概略、つぎのように動作する。まず、言語特徴分析装置によって基本辞書と文書データとから分野依存辞書を作成し、言語解析装置によって基本辞書と分野依存辞書と文書データから構文木等の構造を作成する。パターン抽出装置は、この構造を用いて頻出パターンを抽出し、この頻出パターンに合致する文書データ中の文書を、頻出パターン適合文書記憶部に記憶させると同時に、この頻出パターンを出力する。

一般的に、言語解析装置によって作成される構造として、例えば、

- (A 1) 文中の文節を、構造の節点で表し、
- (A 2) 付属語情報を、節点の属性値で表し、
- (A 3) 係り受け関係を、係り元の節点から係り先の節点への有向枝で表し、
- (A 4) 表層格の情報を、有向枝の属性値で表す

という構造が良く用いられる。

ここで、付属語情報とは、進行や完了などの時制、容易や困難などのモダリティ、及び否定などの付属性能概念である。前記付属語情報は付属語によって文節に付加される情報をいう。

図2に、この形式で表された「彼は車種Aが価格を下げたのを知らない」という文の構文構造の一例を示す。文の文節、「彼」、「車種A」、「価格」、「下げる」、「知る」は節点で表わされる。付属語情報は節点の属性値で表される（節点「知る」の属性値として、付属語情報：否定）。係り受け関係は、係り元の節点から係り先への有向枝で表わされる（例えば「彼」→「知る」）。表層格の情報は有向枝の属性値で表される（例えば「彼」→「知る」の有向枝の属性値として「表層格：は」）。

また、構造中のこれらの情報は、全て属性値を持たないラベル付きの節点と、属性値を持たない有向枝のみからなる構造で表現することも可能である。図3に、この形式で表された「彼は車種Aが価格を下げたのを知らない」という文の構文構造の例を示す。

文の文節「彼」、「車種A」、「価格」、「下げる」、「知る」は、属性値を持たないラベル付きの節点で表わされ（例えば節点「彼」には「表層格：は」のラベルが付加され、「下げる」には、ラベル「付属語情報：完了」、「表層格：を」が付加されている）、係り元の節点から係り先への有向枝は属性値を持たない有向枝とされる。

上記した従来のシステムは下記記載の問題点を有している。なお、以下の問題点及びその解析は、本願発明者らによる研究・検討結果に基づくものである。図4 A～4 D、図5 A及び図5 Bの内容は、問題の在り処を具体的に説明するために、本願発明者らが提示したものである。

第1の問題点として、頻出パターン検出の際に、意味が類似し、かつ連結構造が異なる構造は、全く別のパターンとして判定されてしまうということが挙げられる。

連結構造とは、構造の節点と単語文字列及び有向枝の連結関係と、向きにのみ注目し、付属性能情報を省略した構造のことをいう。

上記第1の問題点が生じる理由は、従来のテキストマイニング装置は、連結構造が異なり、類似した意味を持つ構造を同一と判定する手段を具備していないためである。

属性値を用いた文構造を用いる際に、連結構造が異なり、類似した意味を持つ構造の差異の例として、

- (B 1) 係り受けの向きの差異、
- (B 2) 係り受けの順序の差異、
- (B 3) 同義語の置換による差異、及び、
- (B 4) 並列の構文構造と意味構造の差異

などが挙げられる。

図4 A～4 Dに、これらの連結構造による構造の差異の例を示す。属性値を用いない文構造を用いる際、あらゆる意味の類似した構造の差異は、連結構造の差異で表現される。

図4 Aに示す例では、意味の類似した「速いのは車種A」と「車種Aは速い」の連結構造において、係り元と係り先が相違している。

図4 Bに示す例では、意味の類似した「速く安い車種A」と「安く速い車種A」の連結構造において、係り元の「速い」と「安い」の節点の順序関係が、相違している。

図4 Cに示す例では、意味の類似した「車種Aは速い」と「車種Aは高速だ」のそれぞれの連結構造において、係り先の「速い」と「高速」が相違している。

図4 Dに示す例では、「車種Aと車種Bは速い」の構文構造と意味構造を表わしている。図4 Dにおいて、係り元「車種A」が「車種B」に係り、「車種B」が「速い」に係る連結構造と、係り元「車種A」と「車種B」から係り先「速い」への有向枝を有する連結構造がある。

第2の問題点として、頻出パターン検出の際に異なる属性値を持ち、かつ類似した意味を持つ構造は、全く別のパターンとして判定されてしまうということが挙げられる。

その理由は、従来のテキストマイニング装置では、異なる属性値を持つ構造を、同一と判定することについて、何ら考慮されていないためである。

属性値を用いた文構造を用いる際に、属性値が異なり、かつ類似した意味を持つ構造の差異の例として、付属語情報の差異、表層格の差異などが挙げられる。図5 A及び図5 Bに、これらの属性値による構造の差異の例を示す。

図 5 A に示す例では、類似した意味を持つ「車種Aは加速」と「車種Aの加速」の連結構造において、有向枝の表層格が相違している。

図 5 B に示す例では、類似した意味を持つ「車種Aは速い」と「車種Aは速かった」の連結構造において、係り先の節点「速い」の付属語情報が相違している。

第3の問題点として、テキストマイニング装置の使用者（ユーザ）がどこまで類似した構造を同一な構造と判定して頻出パターンの検出を行うのかを調整できないことが挙げられる。

その理由は、従来のテキストマイニング装置では、使用者が頻出パターン検出の際にどのような構造を同一と判定するかを調整することについて、何ら考慮されていないためである。

したがって、本発明の目的は、類似した意味を持ち、かつ連結構造の異なる構造を、同一のパターンと判定して頻出パターン等の検出を行うテキストマイニング装置及び方法並びにプログラムを提供することにある。

本発明の他の目的は、類似した意味を持ち属性値の異なる構造を同一な構造と判定して頻出パターン検出を行うかを調整できるテキストマイニング装置及び方法並びにプログラムを提供することにある。

本発明のさらに他の目的は、テキストマイニングの使用者がどこまで類似した構造を同一な構造と判定して頻出パターン検出を行うかを調整できるテキストマイニング装置及び方法並びにプログラムを提供することにある。

発明の開示

本願で開示される発明は、上記目的を達成するため、概略以下の構成とされる。

本発明の第 1 の態様に係るテキストマイニング装置は、入力した文書から文構造を作成する手段と、前記文構造の部分構造に対して予め定められた所定の変換操作を行うことで、前記部分構造と意味の類似したパターンの類似構造を作成する手段と、前記意味の類似したパターンを同一パターンと判定してパターン検出を行う手段と、を備えている。

本発明において、前記類似構造を生成する手段は、前記文構造について並列変形を行う手段と、前記文構造の部分構造を生成する手段と、前記文書構造及び／又は

部分構造の有向枝の無向枝化を行う手段と、同義語辞書を参照して前記文書構造及び／又は部分構造中の同義語の置換を行う手段と、前記文書構造及び／又は部分構造における順序木の無順序木化を行う手段と、を備え、前記類似構造を前記部分構造の同値類とする。同値類とは、構造の集合でその各要素を同一の構造として扱うものをいい、二つの同値類に一つでも、同一の要素が含まれる時には、その二つの同値類を同一の同値類と判定する。本発明によれば、生成された類似構造を生成元の文構造の同値類として扱い、頻出パターン検出を行う。

本発明の第2の態様に係るテキストマイニング装置は、第1の態様に係るテキストマイニング装置の構成に含まれる頻出パターン検出手段に代わり、構造中の属性値の差異を無視して、頻出パターンの検出を行う頻出類似パターン検出手段を備え、属性値の異なる類似した構造を同一な構造と判定して頻出パターンの検出を行う。本発明によれば、構造中の属性値が異なる類似した構造を同一と判定して頻出パターン検出を行う。

本発明の第3の態様に係るテキストマイニング装置は、テキストマイニングの対象となる文書の集まりを記憶する記憶部と、前記記憶部の前記文書を解析して文構造を取得する解析部と、使用者の入力から文構造の差異の種別ごとに同一構造と判定するか否かを指定する第1の指定項目を生成する類似構造生成調整部と、使用者の入力から属性値の差異の種別ごとに同一構造と判定するか否かを指定する第2の指定項目を生成し類似構造判定調整部と、前記類似構造生成調整部によって生成された第1の指定項目に従い、前記解析部で得られた文構造の部分構造に対して所定の変換操作を行い、前記部分構造と意味的に類似した類似構造を生成する類似構造生成部と、前記類似構造生成部によって生成された類似構造を生成元の部分構造の同値類として扱い、前記類似構造判定調整部の第2の指定項目に従い、属性値の差異を無視しながら、頻出パターンの検出を行う類似パターン検出部と、を備えている。本発明によれば、構造の同一性の判定を調整するための指定の入力を受け付ける。

本発明のさらに他の態様に係る方法は、

入力した文書から文構造を作成する工程と、

前記文構造の部分構造に対する所定の変換操作を行うことで、前記部分構造と意

味の類似したパターンの類似構造を作成する工程と、

前記意味の類似したパターンを同一パターンと判定してパターン検出を行う工程とを含む。

本発明のさらに他の態様に係る方法は、テキストマイニングの対象となるテキストの集まりを記憶する記憶部のテキストを解析して文構造を取得する工程と、

前記文構造の部分構造に対して意味的に類似したパターンの類似構造を生成する工程と、

生成された類似構造を生成元の部分構造の同値類として扱い、属性値の差異を無視しながらパターンの検出を行う工程とを含む。

本発明のさらに他の態様に係る方法は、テキストマイニングの対象となるテキストの集まりを記憶する記憶部のテキストを解析して文構造を取得する工程と、

入力装置から入力された使用者の入力情報から、文構造（連結構造）の差異の種別ごとに同一構造と判定するか否かを指定する第1の指定項目と、属性値の差異の種別ごとに同一構造と判定するか否かを指定する第2の指定項目を生成するステップと、

文構造（連結構造）の差異の種別ごとに同一構造と判定するか否かを指定する第1の指定項目に従い、前記文構造の部分構造に対して意味的に類似した構造を生成する工程と、

生成された類似構造を生成元の部分構造の同値類として扱い、属性値の差異の種別ごとに同一構造と判定するか否かを指定する第2の指定項目に従い、属性値の差異を無視しながら頻出パターンの検出を行う工程と、を含む。

本発明のさらに他の態様に係るプログラムは、テキストマイニング装置を構成するコンピュータに、

テキストマイニングの対象となるテキストの集まりを記憶する記憶部の前記テキストを解析して文構造を取得する処理と、

前記処理で解析して得られた文構造の部分構造に対して、意味的に類似した構造を生成する処理と、

生成された類似構造を、生成元の部分構造の同値類として扱い、頻出パターンの検出を行う処理と、

を実行させるプログラムよりなる。

図面の簡単な説明

図 1 は従来の技術の構成を示す図である。

図 2 は属性値を用いる形式で表された「彼は私が本を買ったのを知らない」という文の構文構造の例を示す図である。

図 3 は属性値を用いない形式で表された「彼は私が本を買ったのを知らない」という文の構文構造の例を示す図である

図 4 A は連結構造が異なり類似した意味を持つ構造の差異の例を示す図であり、係り受けの向きの差異を示した図である。

図 4 B は連結構造が異なり類似した意味を持つ構造の差異の例を示す図であり、係り受けの順序の差異を示した図である。

図 4 C は連結構造が異なり類似した意味を持つ構造の差異の例を示す図であり、同義語の置換による差異を示す図である。

図 4 D は連結構造が異なり類似した意味を持つ構造の差異の例を示す図であり、並列の構文構造と意味構造の差異を示す図である。

図 5 A は属性値が異なり類似した意味を持つ構造の差異の複数の例を示す図であり、付属語情報の差異を示す図である。

図 5 B は属性値が異なり類似した意味を持つ構造の差異の複数の例を示す図であり、表層格の差異を示す図である。

図 6 は本発明の第 1 の実施の形態の構成を示す図である。

図 7 は第 1 の実施の形態の動作を説明するための流れ図である。

図 8 は本発明の実施の形態における類似構造生成手段 2 2 の動作を説明するための流れ図である。

図 9 は本発明の第 2 の実施の形態の構成を示す図である。

図 1 0 は本発明の第 2 の実施の形態の動作を説明するための流れ図である。

図 1 1 は本発明の第 3 の実施の形態の構成を示す図である。

図 1 2 は本発明の第 3 の実施の形態の動作を説明するための流れ図である。

図 1 3 は本発明の第 3 の実施の形態における類似構造生成手段 2 2 の動作を説

明するための流れ図である。

図14は本発明の第4の実施の形態の構成を示す図である。

図15は本発明の第1～第3実施例で使用するテキストDB中のテキスト集合の例を示す図である。

図16Aは言語解析手段21で得られる文1の文構造を示す図である。

図16Bは言語解析手段21で得られる文2の文構造を示す図である。

図16Cは言語解析手段21で得られる文3の文構造を示す図である。

図17は本発明の第1～第3の実施例において使用する、同義語辞書の構造を示す図である。

図18は本発明の第1～第3の実施例において、図8のステップA2-1における処理を示す図である。

図19は本発明の第1～第3の実施例において、図8のステップA2-2における処理を示す図である。

図20Aは部分構造2a-0に対する無効枝化処理（ステップA2-3）を示す図である。

図20Bは部分構造2c-0に対する無効枝化処理（ステップA2-3）を示す図である。

図20Cは部分構造2a-1に対する無効枝化処理（ステップA2-3）を示す図である。

図20Dは部分構造2g-0に対する無効枝化処理（ステップA2-3）を示す図である。

図20Eは部分構造2b-0に対する無効枝化処理（ステップA2-3）を示す図である。

図21は本発明の第1～第3の実施例において、図8のステップA2-6における処理を示す図である。

図22は本発明の第1、第2の実施例において、類似構造生成手段22が文3の文構造の全体からなる部分構造3a-0の類似構造を生成する処理を示す図である。

図23は本発明の第1～第3の実施例において文1の文構造から生成される部

分構造の同値類を示す図である。

図24は本発明の第1～第3の実施例において文2の文構造から生成される部分構造の同値類を示す図である。

図25は本発明の第1、第2の実施例において、文3の文構造から生成される部分構造の同値類を示す図である。

図26は本発明の第1の実施例において、図23～25に示す同値類の集合から検出される頻出パターンを示す図である。

図27は本発明の第2の実施例において、図23～25に示す同値類の集合から検出される頻出パターンを示す図である。

図28は本発明の第3の実施例において、類似構造生成手段22が文3の文構造の全体からなる部分構造3a-0の類似構造を生成する処理を示す図である。

図29は本発明の第3の実施例において、文3の文構造から生成される部分構造の同値類を示す図である。

図30は本発明の第3の実施例において、図23、24及び図29に示す同値類の集合から検出される頻出パターンを示す図である。

発明を実施するための最良の形態

以下、発明を実施するための最良の形態について図面を参照して詳細に説明する。

図6を参照すると、本発明の第1の実施の形態に係る装置は、情報を記憶する記憶装置1と、プログラム制御により動作するデータ処理装置2と、検出されたパターンを出力する出力装置3と、を有している。記憶装置1はテキストデータベース(DB)11を含む。テキストDB11は、テキストマイニングの対象となるテキストの集合を記憶している。

データ処理装置2は、言語解析手段21と、類似構造生成手段22と、頻出パターン検出手段23を含む。これらの手段はそれぞれ、おおむね以下のように動作する。

言語解析手段21は、テキストDB11からテキスト集合を読み込み、その結果、集合中の各テキストを解析して文構造を得る。

類似構造生成手段22は、言語解析手段21から送出された文構造の集合中の各

文構造を構成する全ての部分構造を抽出し、前記各部分構造の全ての類似構造を生成して、その結果、類似構造と生成元の部分構造を同値類とする。

頻出パターン検出手段 23 は、類似構造生成手段 22 から送出された部分構造の同値類の集合から頻出するパターンを検出し、出力装置 3 へ送出する。

図 7 は、本実施形態の動作を説明するための流れ図である。次に、図 6 及び図 7 を参照して、本発明の第 1 の実施形態に係る装置の動作について詳細に説明する。

まず、言語解析手段 21 が、テキスト DB11 から、テキスト集合を読み込む。言語解析手段 21 は、テキスト集合中の各テキストに対し解析を行い、解析結果として、文構造を生成し、類似構造生成手段 22 に送出する（図 7 のステップ A1）。

次に、類似構造生成手段 22 は、与えられた文構造の集合中の部分構造の全ての類似構造を生成し、その結果、類似構造を生成元の部分構造の同値類とする。類似構造生成手段 22 は、その後、同値類の集合を頻出パターン検出手段 23 に送出する（図 7 のステップ A2）。

さらに、頻出パターン検出手段 23 は、与えられた部分構造の同値類から、頻出パターンの検出を行う（図 7 のステップ A3）。

頻出パターン検出手段 23 は、検出した頻出パターンを出力装置 3 に出力する（図 7 のステップ A4）。

図 8 は、図 7 のステップ A2 における、類似構造生成手段 22 の動作の詳細なフローチャートを示す図である。

図 8 を参照すると、類似構造生成手段 22 は、まず並列構文の構文構造と意味構造の違いに対応するための「並列の変形」を行う（図 8 のステップ A2-1）。

次に、文構造全体だけではなく部分構造からもパターン検出を行うための「部分構造の生成」を行う（図 8 のステップ A2-2）。

次に、係り受けの向きの差異に対応するための「有向枝の無向枝化」を行う（図 8 のステップ A2-3）。

次に、同義語の差異に対応するための「同義語の置換」を行う（図 8 のステップ A2-4）。

その係り受けの順序の違いに対応するための「順序木の無順序木化」を行う（図 8 のステップ A2-5）。

最後に、類似構造を、生成元の部分構造の同値類の要素としてすることで、「同値類の生成」を行う（図8のステップA2-6）。

以下、本発明の第1の実施の形態に係る装置の作用効果について説明する。

本実施の形態に係る装置は、類似構造生成手段22が生成した類似構造を、元の構造の同値類として扱い、頻出パターン検出を行うように構成されている。このため、連結構造は異なるが、類似した意味を持つ構造を、同一の構造と判定して、頻出パターンを検出できる。

次に、本発明の第2の実施の形態について図面を参照して詳細に説明する。

図9を参照すると、本発明の第2の実施の形態に係る装置は、第1の実施の形態に係る装置と、データ処理装置4が、データ処理装置2の頻出パターン検出手段23の代わりに頻出類似パターン検出手段24を備えている以外は同じである。言語解析手段21、類似構造生成手段22は、前記第1の実施の形態のものと同一である。

本実施の形態において、頻出類似パターン検出手段24は、類似構造生成手段22から送出された部分構造の同値類の集合から、属性値の相違を無視しながら、頻出パターンの検出を行い、検出した頻出パターンを出力装置3に送出する。

図10は、本発明の第2の実施形態に係る装置の動作を説明するための流れ図である。次に、図9及び図10を参照して、本実施形態に係る装置の動作について詳細に説明する。本実施形態においては、図7のステップA3の代わりに、ステップB3が実行される。図10のステップA1、A2、A4で示される処理は、前記第1の実施の形態における処理と同一であるため、説明は省略する。

前記第1の発明の実施の形態では、頻出パターン検出手段23は、連結構造が同一でも属性値の異なる構造は同一と判定せずに、頻出パターンの検出を行っていた。

本実施の形態では、頻出類似パターン検出手段24は、類似構造生成手段22から与えられた同値類の集合を、連結構造が同一で属性値の異なる構造も同一な構造と判定しながら頻出パターンの検出を行い、検出された頻出パターンを出力装置3に送出する（図10のステップB3）。

次に、本発明の第2の実施形態に係る装置の作用効果について説明する。

本発明の第2の実施の形態では、頻出類似パターン検出手段24は、連結構造は

同一で属性値の異なる構造も同一な構造と判定しながら頻出パターンの検出を行うように構成されている。このため、意味は類似しているが属性値の異なる構造も同一な構造と判定して頻出パターンの検出を行うことができる。

次に、本発明の第3の実施形態について図面を参照して詳細に説明する。

図1 1を参照すると、本発明の第3の実施の形態は、入力装置6を備え、データ処理装置5が類似構造生成調整手段25及び類似構造判定調整手段26を備えている以外は前記第2の実施の形態と同じである。

入力装置6は、使用者から、

- ・文構造の差異の種別ごとに同一構造と判定するか否かを指定するための入力と、
- ・属性値の種別ごとに値の差異を無視するか否かを指定するための入力と、

を受け付け、それを、類似構造生成調整手段25と類似構造判定調整手段26に送出する。

入力装置6で受け付ける指定の入力の例としては、

- ・「使用者から文構造の差異の種別ごとに同一構造と判定するか否かと属性値の種別ごとに値の差異を無視するか否かについての指定項目」、
- ・「頻出パターン検出の際に同一パターンを持っていると判定しない文の例」、
- ・「頻出パターン検出の際に同一パターンを持っていると判定する文の例」

などが挙げられる。

類似構造生成調整手段25は、入力装置6から与えられた指定から、連結構造の差異の種別ごとに同一構造と判定するか否かを決定し、その指定項目を、類似構造生成手段22に送出する。

また、類似構造判定調整手段26は、入力装置6から与えられた指定から、属性値の種別ごとに値の差異を無視するか否かを決定し、その指定項目を、頻出類似パターン検出手段24に送出する。

類似構造生成手段22は、類似構造生成調整手段25からの指定に従って、言語解析手段21より与えられた集合中の各構造の部分構造について、該部分構造の類似構造の生成を行い、その結果、生成された各類似構造を、それぞれの生成元の部分構造の同値類とする。

頻出類似パターン検出手段24は、類似構造判定調整手段26からの指定に従つ

て、属性値の差異の無視を行いながら、類似構造生成手段 2 2 より与えられた同値類の集合から頻出パターンの検出を行う。

図 1 2 は、本発明の第 3 の実施の形態に係る装置の動作を説明するための流れ図である。次に、図 1 1 及び図 1 2 のフローチャートを参照して本発明の第 3 の実施の形態に係る装置の動作について詳細に説明する。

最初に、言語解析手段 2 1 がテキスト DB 1 1 からテキスト集合を読み込む。

言語解析手段 2 1 は、テキスト集合中の各テキストに対して解析を行い、解析結果として文構造を生成し、類似構造生成手段 2 2 に送出する（図 1 2 のステップ A 1）。図 1 2 のステップ A 1 における言語解析手段 2 1 の動作は、前記第 1 の実施の形態における言語解析手段 2 1 と同一である。

次に、入力装置 6 が、使用者から文構造の差異の種別ごとに同一構造と判定するか否かを指定するための入力と、属性値の種別ごとに値の差異を無視するか否かを指定するための入力とを受け付け、それぞれ類似構造生成調整手段 2 5 と類似構造判定調整手段 2 6 に送出する（図 1 2 のステップ C 1）。

類似構造生成調整手段 2 5 は、入力装置 6 からの指定を受け、文構造の差異の種別ごとに同一構造と判定するか否かの指定項目を生成し、類似構造生成手段 2 2 に送出する。また、類似構造判定調整手段 2 6 は、入力装置 6 からの指定を受け、属性値の種別ごとに値の差異を無視するか否かの指定項目を生成し頻出類似パターン検出手段 2 4 に送出する（図 1 2 のステップ C 2）。

類似構造生成手段 2 2 は、類似構造生成調整手段 2 5 からの指定に従って、言語解析手段 2 1 より与えられた集合中の各文構造を構成する部分構造の類似構造の生成を行い、その結果、生成された各類似構造をそれぞれの生成元の部分構造の同値類とし、当該同値類の集合を頻出類似パターン検出手段 2 4 に送出する（図 1 2 のステップ C 3）。

頻出類似パターン検出手段 2 4 は、類似構造判定調整手段 2 6 からの指定に従って属性値の無視を行いながら、類似構造生成手段 2 2 より与えられた同値類の集合から頻出パターンの検出を行う（図 1 2 のステップ C 4）。

最後に、頻出類似パターン検出手段 2 4 は、検出した頻出パターンを出力装置 3 に出力する（図 1 2 のステップ A 4）。

図13は、図12のステップC3における、類似構造生成手段22の動作の詳細なフローチャートである。

図13を参照すると、類似構造生成手段22は、

ステップC3-1の判定において、並列の変形が指定されている場合、並列の変形（図13のステップA2-1）を行って部分構造の生成（図13のステップA2-2）を行い、並列の変形が指定されていない場合、ステップA2-2の処理へ移行する。並列の変形、部分構造の生成は、図8のステップA2-1、A2-2と同一である。

ステップC3-2の判定において、有向枝の無向枝化が指定されている場合、有向枝の無向枝化（図13のステップA2-3）を行い、指定されていない場合、ステップC3-3の処理に移行する。有向枝の無向枝化は、図8のステップA2-3と同一である。

ステップC3-3の判定において、同義語の置換が指定されている場合、同義語の置換（図13のステップA2-4）を行い、同義語の置換が指定されていない場合、ステップC3-4の処理に進む。同義語の置換は、図8のステップA2-4と同一である。

ステップC3-3の判定において、順序木の無順序木化が指定されている場合、順序木の無順序木化（図13のステップA2-5）を行い、指定されていない場合、ステップA2-6の処理に移行する。

ステップA2-6では、同値類を生成する。順序木の無順序木化、同値類を生成は、図8のステップA2-5、A2-6と同一である。

このように、本実施の形態では、並列の変形（図13のステップA2-1）、有向枝の無向枝化（図13のステップA2-3）、同義語の置換（図13のステップA2-4）、及び、順序木の無順序木化（図13のステップA2-5）が、類似構造生成調整手段25から与えられた指定により、実行の有無が制御される点で、図8に示した前記第1の実施の形態の類似構造生成手段22と相違している。

使用者は、出力されたパターンを参照して、ステップC1に戻りどこまで類似した構造を同一と判定するかを指定するための入力を再度行ったうえで本発明に頻出パターン検出を再度行わせることができる。

次に、本発明の第3の実施の形態に係る装置の作用効果について説明する。

本実施の形態では、類似構造生成調整手段と類似構造判定調整手段が使用者からの指定に基づきどこまで類似した構造を同一な構造と判定するかの調整を行うように構成されている。このため、使用者がどこまで類似した構造を同一な構造と判定して頻出パターン検出を行うかを調整できる。

次に、本発明の第4の実施の形態について図面を参照して詳細に説明する。

図14を参照すると、本発明の第4の実施の形態に係る装置は、前記した第1、第2、第3の実施の形態をプログラムにより構成したものである。図14はこの場合に、そのプログラムにより動作されるコンピュータの構成を示す図である。

テキストマイニング用プログラム7は、データ処理装置8に読み込まれ、データ処理装置8の動作を制御する。データ処理装置8はテキストマイニング用プログラム7の制御により以下の処理、すなわち第1、第2及び第3の実施の形態におけるデータ処理装置2、4及び5による処理と同一の処理を実行する。

次に、本発明を具体的な実施例を即して詳細に説明する。

まず、本発明の第1の実施例について図面を参照して説明する。本発明の第1の実施例は前記第1の実施の形態の一具体例である。

本実施例における装置は、図6のデータ処理装置2をパソコン・コンピュータで、記憶装置1を磁気ディスク記憶装置で、出力装置3としてディスプレイを備えて構成されている。

パソコン・コンピュータ2は、言語解析手段21、類似構造生成手段22、頻出パターン検出手段23として機能する中央演算装置(CPU)を有している。磁気ディスク記憶装置には、テキストDB11としてテキスト集合が記憶されている。

図15は、テキスト集合の内容を示す図である。

言語解析手段21は、テキストDB11中の図15に示されるテキスト集合の各テキストに対して言語解析を行い、その結果、各テキストの文構造を得る(図7のステップA1)。

図16A～図16Cに、それぞれ言語解析手段21で得られる文1～文3の文構造を示す。

次に、類似構造生成手段22は、図16A～図16Cに示される各文構造を構成

する部分構造の全ての類似構造を生成し、その結果、生成された類似構造を生成元の部分構造の同値類とする（図7のステップA2）。

本実施例では、図16Bに示される文2（「速く安い車種A」）の文構造から、部分構造の同値類を生成する様子を例にとって説明する。この例は、図18～21に示されている。

類似構造生成手段22は、まず、図18に示すように、並列構造の変形を行い（図8のステップA2-1）、次に部分構造2a-0において、並列関係にある「速い」と「安い」の接続関係を変形し、類似構造2a-1を生成する。

類似構造生成手段22は、次に、図19に示すように、部分構造の生成を行い（図8のステップA2-2）、部分構造2a-0から、2単語の関係を表す部分構造2c-0及び2g-0と、1単語の部分構造2d-0、2e-0及び2f-0を生成する。

類似構造生成手段22は、また、類似構造2a-1から、部分構造2a-0に含まれない2単語の関係を表す部分構造2b-0を生成する。

なお、部分構造2a-0と類似構造2a-1の両方から生成される構造は1つにまとめて扱う。

また、ここで部分構造を生成するのに用いた部分構造2a-0、及び類似構造2a-1も、今後の類似構造生成において、部分構造及び類似構造として扱う。

次に、類似構造生成手段22は有向枝の無向枝化を行う（図8のステップA2-3）。この例においては、ステップA2-2において生成した部分構造の全ての有向枝が無向枝化され、新たな類似構造が生成される。図20Aに示すように、例えば部分構造2a-0の有向枝を無向枝化して、類似構造2a-2が生成される。なお、1単語からなり有向枝を持たない部分構造2d-0、2e-0及び2f-0は、ステップA2-3では変形が行われないため、図20A～図20Eでは省略されている。

次に、同義語の置換が行われる（図8のステップA2-4）。本実施例における「同義語の置換」では、ユーザによりあらかじめ与えられた同義語辞書に定義された被置換語を代表語に置き換えるものとする。

また、本実施例に用いる同義語辞書は、図17に示されるように、被置換語「高

速」を代表語「速い」に置き換える 1 つの辞書項目のみが登録された同義語辞書が指定されたものとしている。

この時点で生成された部分構造及び類似構造には、被置換語「高速」が含まれないため、ステップ A 2 – 4 では、変形が発生しない。そのため、ここではステップ A 2 – 4 による変形の図を省略している。

次に、順序木の無順序木化が行われる（図 8 のステップ A 2 – 5）。ここでは、文構造の木構造において、兄弟関係にある単語を 50 音順にソートすることによって、順序木の無順序木化を行う。

なお、順序木の無順序木化を行うための他の方法として、

- ・兄弟関係にある単語を 50 音順以外の一定の法則に従いソートする方法や、
- ・ソートを行わずに頻出類似パターン検出時に兄弟関係にある単語の順序だけが異なる木を同一と判定する方法を用いてもよい。

生成された部分構造及び類似構造では、類似構造 2 a – 1 及び 2 a – 3（図 20 C）を除いた部分構造及び類似構造では兄弟関係になっている単語が存在しない。類似構造 2 a – 1 及び 2 a – 3 では、既に兄弟関係にある単語が 50 音順に並んでいる。このため、実質的に変形が発生しない。そのため、ここではステップ A 2 – 5 による変形の図を省略している。

最後に、類似構造を生成元の部分構造の同値類として、同値類の生成が行われる（図 8 のステップ A 2 – 6）。

図 20 A～図 20 E に示された部分構造及び類似構造の集合において、各類似構造を生成元の部分構造の同値類することで生成される同値類を図 21 に示す。部分構造 2 a – 0 と、部分構造 2 a – 0 の有向枝を無向枝化することで生成された類似構造 2 a – 2 と、部分構造 2 a – 0 を並列変形した類似構造 2 a – 1 と、類似構造 2 a – 1 の有向枝を無向枝化することで生成された類似構造 2 a – 3 とは同値類 2 a を構成している。

部分構造 2 b – 0 と、部分構造 2 b – 0 の有向枝を無向枝化することで生成された類似構造 2 b – 1 は、同値類 2 b を構成している。部分構造 2 c – 0 と、部分構造 2 c – 0 の有向枝を無向枝化することによって生成された類似構造 2 c – 1 は、同値類 2 c を構成している。部分構造 2 g – 0 と、部分構造 2 g – 0 の有向枝を無

向枝化することによって生成された類似構造 2 g - 1 は、同値類 2 g を構成している。部分構造 2 d - 0、2 e - 0、2 f - 0 は、類似構造と部分構造は同一である。

図 18～図 21 に示したように、本実施例において、文 2 の文構造（図 16 B 参照）から、類似構造生成手段 2 2 が同値類を生成する例においては、同義語の置換（図 8 のステップ A 2 - 4）及び順序木の無順序木化（図 8 のステップ A 2 - 5）で変形は行われない。

図 22 に示すように、文 3 の文構造（図 16 C 参照）を構成する一の部分構造に対して、類似構造生成手段 2 2 による変形処理が行われる。以下、同義語の置換（図 8 のステップ A 2 - 4）及び順序木の無順序木化（図 8 のステップ A 2 - 5）で発生する変形の例を説明する。

まず文 3 の文構造を表す部分構造 3 a - 0 に対して並列の変形（図 8 のステップ A 2 - 1）が行われる。ここでは、部分構造 3 a - 0 が並列の構造を含まず変形が行われないため、図 22 には、並列の変形による結果の構造は含まれない。

次に、部分構造 3 a - 0 から部分構造の生成（図 8 のステップ A 2 - 2）が行われる。ここでは、部分構造 3 a - 0 に行われる構造変形にのみ注目して説明するため、部分構造 3 a - 0 から、他の部分構造を生成する処理である部分構造の生成は省略する。

次に、部分構造 3 a - 0 に対して、有向枝の無向枝化（図 8 のステップ A 2 - 3）が行われる。部分構造 3 a - 0 の「安い」から、「車種A」への有向枝と、「高速」から「車種A」への有向枝が無向枝化される。その結果、類似構造 3 a - 1 が生成される（図 22：ステップ A 2 - 3）。

次に、類似構造 3 a - 1 に対して、同義語の置換（図 8 のステップ A 2 - 4）が行われる。ここでは、図 17 に示される同義語辞書を用いているため、被置換語「高速」が代表語「速い」に置き換えられる。類似構造 3 a - 1 に含まれる被置換語「高速」も代表語「速い」に置き換えられ、類似構造に変形される（図 22：ステップ A 2 - 4）。

次に、類似構造 3 a - 1 に対して、順序木の無順序木化（図 8 のステップ A 2 - 5）が行われる。ここでは、兄弟関係にある単語を、50 音順にソートすることで順序木の無順序木化が行われる。このため、類似構造 3 a - 1 において兄弟関係に

ある「安い」と「速い」の順序を入れ替え、50音順にソートにされ、類似構造に変換される（図22：ステップA2-5）。

このようにして生成された類似構造に対して同値類の生成（図8のステップA2-6）が行われる。尚、本実施例では、部分構造3a-0から生成される一つの類似構造3a-1に行われる変形のみに注目して説明しているためその説明を省略する。

このようにして、類似構造生成手段22が、部分構造と類似構造及び同値類の生成を行うことで、本実施例では、図16Aの文1の文構造から、図23に示すような同値類が生成される。図16Bの文2の文構造から、図24に示すような同値類が生成される。また図16Cの文3の文構造から、図25に示すような同値類が生成される。

ただし、本来は、図22における変形の途中経過（図22：ステップA2-3からステップA2-4における類似構造3a-1）のように、形の違う類似構造も生成されている。尚、説明を分かりやすくするため、頻出パターンの検出に用いられない構造は、図23～図25の同値類からは省略している。

次に、頻出パターン検出手段23は、図23～図25に示される同値類の集合から頻出パターン（頻出する同値類）の検出を行う（図7のステップA3）。

この際、頻出パターン検出手段23は、要素の少なくとも一つが同一である同値類は、同一と判定して、頻出パターンの検出を行う。

例えば、本実施例においては、図23の同値類1cの要素である類似構造1c-1と、図24の同値類2bの要素である類似構造2b-1は、どちらも「車種A」と「速い」が無向枝で連結された構造で、属性値の差分もないため、同一の構造である。

従って、頻出パターン検出手段23は、図23の同値類1cと図24の同値類2bを同一と判定する。

図23～図25を参照すると、

「類似構造1c-1、類似構造2b-1と、類似構造3c-1」、

「部分構造1d-0、部分構造2d-0と、類似構造3e-1」、

「部分構造1e-0、部分構造2f-0と、部分構造3f-0」、

「部分構造 1 f - 0 と部分構造 2 e - 0」

がそれぞれ同一の構造となっている。

「要素の少なくとも一つが同一である同値類は同一と判定する」という同値類の性質により、図 2 3～図 2 5 に示される同値類のうち、

「同値類 1 c、 2 b、 及び、 3 c」、

「同値類 1 d、 2 d、 及び、 3 e」、

「同値類 1 e、 2 f、 及び、 3 f」、

「同値類 1 f、 及び、 2 e」

がそれぞれ同一の同値類と判定される。

本実施例では、3 回以上出現する同値類を頻出パターンとする。なお、どのような出現回数の同値類を頻出パターンとして検出するかは、使用者がテキストマイニングを実行する前に決定することができる。

この場合、

「同値類 1 c、 2 b、 及び、 3 c」、

「同値類 1 d、 2 d、 及び、 3 e」、

「同値類 1 e、 2 f、 及び、 3 f」

が頻出パターンとして検出される。

最後に、そのようにして抽出された頻出パターンを表す構造を出力装置 3 に表示する（図 7 のステップ A 4）。

図 2 6 は、本実施例において、出力装置 3 が output する頻出パターンの表現の一例を示す図である。本実施例では、頻出パターンを表す同値類の要素である類似構造を、頻出パターンの表現として用いている。

類似構造を生成し、同値類を生成して頻出パターンの検出を行うことによって、「部分構造 1 c - 0（図 2 3）、部分構造 2 b - 0（図 2 4）、及び、部分構造 3 c - 0（図 2 5）」のように類似した意味を持つが、連結構造の異なる部分構造を同一と判定し、頻出パターンとして検出することができる。

次に、本発明の第 2 の実施例について図面を参照して説明する。本実施例は、前記第 2 の実施の形態に対応するものである。

本実施例に係る装置は、データ処理装置 4 をパーソナル・コンピュータで、記憶

装置1を磁気ディスク記憶装置で、出力装置3としてディスプレイを備えて構成されている。

パソコン・コンピュータ4は、言語解析手段21、類似構造生成手段22、頻出類似パターン検出手段24として機能する中央演算装置(CPU)を有し、磁気ディスク記憶装置には、テキストDB11としてテキスト集合が記憶されている。テキスト集合としては、前記第1の実施例と同様、図15に示した文1～文3を使用する。

言語解析手段21は、テキストDB11中の図15に示されるテキスト集合の各テキストに対して、言語解析を行い、各テキストの文構造を得る(図10のステップA1)。ここで得られる文構造は、前記第1の実施例と同様、図16A～図16Cのようになる。

次に、類似構造生成手段22は、図16A～図16Cに示される各文構造を構成する部分構造の全ての類似構造を生成し、その結果、生成された類似構造を生成元の部分構造の同値類とする(図10のステップA2)。ここで得られる同値類は、前記第1の実施例と同様、図23～図25のようになる。

次に、頻出類似パターン検出手段24は、図23～図25に示される同値類の集合から、属性値の差異を無視しながら頻出パターン(頻出する同値類)の検出を行う(図10のステップB3)。

頻出類似パターン検出手段24は、要素の少なくとも一つが同一である同値類は同一と判定して、頻出パターンの検出を行う。ただし、本実施例の頻出類似パターン検出手段24は、表層格や付属語情報などの属性値の差異を無視して、類似構造の同一性の判定を行っており、この点で、前記第1の実施例の頻出パターン検出手段23と相違している。

例えば、図23の類似構造1a-1と図24の類似構造2a-3は、どちらも、「車種A」と「速い」及び「安い」が無向枝で連結された構造である。しかし、表層格が異なるため、前記第1の実施例の頻出パターン検出手段23では、同一と判定されない。一方、本実施例の頻出類似パターン検出手段24では、同一と判定される。

本実施例においては、図23～図25を参照すると、

「類似構造 1 a - 1、類似構造 2 a - 3、及び、類似構造 3 a - 1」、
「類似構造 1 b - 1、類似構造 2 c - 1 と、類似構造 3 b - 1」、
「類似構造 1 c - 1、類似構造 2 b - 1、及び、類似構造 3 c - 1」、
「部分構造 1 d - 0、部分構造 2 d - 0、及び、類似構造 3 e - 1」、
「部分構造 1 e - 0、部分構造 2 f - 0、及び、部分構造 3 f - 0」、
「部分構造 1 f - 0、部分構造 2 e - 0、及び、部分構造 3 d - 0」
がそれぞれ頻出類似パターン検出手段 2 4 に同一の構造と判定される。

頻出類似パターン検出手段 2 4 は、要素の少なくとも一つが同一である同値類は同一と判定するため、

「同値類 1 a、2 a、及び、3 a」、
「同値類 1 b、2 c、及び、3 b」、
「同値類 1 c、2 b、及び、3 c」、
「同値類 1 d、2 d、及び、3 e」、
「同値類 1 e、2 f、及び、3 f」、
「同値類 1 f、2 e、及び、3 d」

をそれぞれ同一の同値類と判定する。

本実施例では、前記第 1 の実施例と同様に、3 回以上出現する同値類を頻出パターンとする。この場合、

「同値類 1 a、2 a、及び、3 a」、
「同値類 1 b、2 c、及び、3 b」、
「同値類 1 c、2 b、及び、3 c」、
「同値類 1 d、2 d、及び、3 e」、
「同値類 1 e、2 f、及び、3 f」、
「同値類 1 f、2 e、及び、3 d」

が頻出パターンとして検出される。

最後に、そのようにして抽出された頻出パターンを表す構造を、出力装置 3 に表示する（図 10 のステップ A 4）。

本実施例において、出力装置 3 が output する頻出パターンの表現は図 27 のようになる。本実施例では、前記第 1 の実施例と同様に、頻出パターンを表す同値類の要

素である類似構造を、頻出パターンの表現として用いている。

このようにして、属性値の差異を無視して頻出パターンの検出を行うことによつて、

「部分構造 1 b - 0 (図 23)、部分構造 2 c - 0 (図 24) と部分構造 3 b - 0 (図 25)」、

「部分構造 1 f - 0 (図 23)、部分構造 2 e - 0 (図 24) と部分構造 3 f - 0 (図 25)」

のように、類似した意味を持つが属性値の異なる部分構造を同一と判定し、頻出パターンとして、検出を行うことができる。

次に、本発明の第 3 の実施例について図面を参照して説明する。本実施例は、本発明の第 3 の実施の形態に対応するものである。

本実施例に係る装置は、データ処理装置 5 をパソコン・コンピュータで、記憶装置 1 を磁気ディスク記憶装置で、出力装置 3 としてディスプレイを、入力装置 6 としてキーボードを備えて構成されている。

パソコン・コンピュータ 5 は、言語解析手段 2 1、類似構造生成手段 2 2、頻出類似パターン検出手段 2 4、類似構造生成調整手段 2 5、類似構造判定調整手段 2 6 として機能する中央演算装置 (CPU) を有している。磁気ディスク記憶装置には、テキスト DB 1 1 としてテキスト集合が記憶されている。テキスト集合としては、前記第 1、第 2 の実施例と同様、図 1 5 に示した文が用いられる。

言語解析装置 2 1 は、テキスト DB 1 1 中の図 1 5 に示されるテキスト集合の各テキストに対して、言語解析を行い、各テキストの文構造を得る (図 1 2 のステップ A 1)。ここで得られる文構造は、前記第 1、第 2 の実施例と同じく、図 1 6 A ～図 1 6 C のようになる。

次に、使用者は、入力装置 6 を用いて、

- ・文構造の差異の種別ごとに同一構造と判定するか否かを指定するための入力と、
- ・属性値の種別ごとに値の差異を無視するか否かを指定するための入力を行う (図 1 2 のステップ C 1)。

本実施例において、例えば

「連結構造の差異については、係り受けの向きの差異と係り受けの順序の差異は

同一と判定し、同義語の置換による差異は同一と判定しない。属性値の差異については、「付属語情報の差異と表層格の差異は同一と判定する」という入力を行ったとする。

入力装置 6 は、使用者から受け付けた入力を、類似構造生成調整手段 2 5 と類似構造判定調整手段 2 6 に送出する。

次に、類似構造生成調整手段 2 5 は、入力装置 6 から使用者の指定を受け取り、類似構造生成手段 2 2 の動作を制御する（図 1 2 のステップ C 2）。

本実施例においては、類似構造生成調整手段 2 5 は、入力装置 6 から、「連結構造の差異については、係り受けの向きの差異と係り受けの順序の差異は同一と判定し、同義語の置換による差異は同一と判定しない。属性値の差異については、「付属語情報の差異と表層格の差異は同一と判定する」という指定を受け取ると、

類似構造生成手段 2 2 が行う、文構造の部分構造から類似構造を生成する際の変形処理、すなわち並列構造の変形（図 1 3 のステップ A 2-1）、有向枝の無向枝化（図 1 3 のステップ A 2-3）及び順序木の無順序木化（図 1 3 のステップ A 2-5）は行われる。しかし、類似構造生成調整手段 2 5 は、同義語の置換（図 1 3 のステップ A 2-4）がスキップされるように類似構造生成手段 2 2 の動作を制御する。

一方、類似構造判定調整手段 2 6 は、入力装置 6 から使用者の入力を受け取り、頻出類似パターン検出手段 2 4 の動作を制御する（図 1 2 のステップ C 2）。

本実施例においては、類似構造生成調整手段 2 6 は、入力装置 6 から、「連結構造の差異については、係り受けの向きの差異と係り受けの順序の差異は同一と判定し、同義語の置換による差異は同一と判定しない。

属性値の差異については、「類似構造生成調整手段 2 6 は、付属語情報の差異と表層格の差異については同一と判定する」という指定を受け取り、頻出類似パターン検出手段 2 4 が類似構造の同一性判定の処理を、表層格の差異及び付属語情報の差異を無視して行うように制御する。

次に、類似構造生成手段 2 2 は、図 1 6 A～図 1 6 C に示される各文構造の部分構造についてステップ C 2 で生成した指定項目に従い、同義語の置換（図 1 3 のス

ステップA 2－4) を飛ばして類似構造を生成し、その結果、生成された類似構造を生成元の部分構造の同値類とする(図12のステップC 3)。

以下、図16Cに示される文3の文構造の一部分構造に対して、類似構造生成手段22が行う変形を例にとって説明する。図28に、その一例を示す。

まず、文3の文構造を表す部分構造3a－0に対して、並列の変形(図13のステップA 2－1)が行われる。ただし、図28に示す例では、部分構造3a－0が並列の構造を含まず変形が行われないため、図28には、並列の変形による結果の構造は含まれない。

次に、部分構造3a－0から部分構造の生成(図13のステップA 2－2)が行われる。尚、部分構造3a－0に行われる構造変形にのみ注目して説明するため、部分構造3a－0から他の部分構造を生成する処理である部分構造の生成は省略する。

次に、部分構造3a－0に対して有向枝の無向枝化(図13のステップA 2－3)が行われる。部分構造3a－0の「安い」から「車種A」への有向枝と、「高速」から「車種A」への有向枝が無向枝化される。その結果、類似構造3a－2が生成される(図28のステップA 2－3)。

同義語の置換(図13のステップA 2－4)は、類似構造生成調整手段25より与えられた指定により、ステップC 3－3の判定でスキップされるため、実行されない。

次に、類似構造3a－2に対して、順序木の無順序木化(図13のステップA 2－5)が行われる。ここでは、兄弟関係にある単語を50音順にソートすることで、順序木の無順序木化が行われる。類似構造3a－2(図28のステップA 2－3処理後における類似構造)において、兄弟関係にある単語「安い」と「高速」の順序を入れ替えるように、前記単語が50音順にソートされる。その結果、類似構造3a－2は図28のステップA 2－5処理後における類似構造に変換される。

このようにして生成された類似構造に対して、同値類の生成(図13のステップA 2－6)が行われる。尚、部分構造3a－0から生成される一つの類似構造3a－2に行われる変形のみに注目して説明しているため、省略する。

本実施例における変形では、同義語の置換(図13のステップA 2－4)が飛ば

されるため、図28のステップA2-5処理後における類似構造3a-2には、被置換語「高速」が残っている。一方、図22に示した前記第1、第2の実施例における変形の例、すなわちステップA2-5処理後における類似構造3a-1では、被置換語「高速」が代表語「速い」に置換されている。

本実施例では、このようにして、類似構造生成手段22が部分構造と類似構造及び同値類の生成を行うことで、図16Aに示される文1の文構造から、図23に示される同値類が生成され、図16Bに示される文2の文構造から、図24に示される同値類が生成され、図16Cに示される文3の文構造から図29に示される同値類が生成される。

次に、頻出類似パターン検出手段24は、図23、図24、及び図29に示される同値類の集合から、ステップC2で、類似構造判定調整手段26が指定した属性値の差異を無視しながら頻出パターンの検出を行う（図12のステップC4）。

頻出類似パターン検出手段24は、要素の少なくとも一つが同一である同値類は同一と判定して、頻出パターンの検出を行う。

本実施例においては、頻出類似パターン検出手段24は、類似構造判定調整手段26からの指定により、どの属性値の差異を無視して類似構造の同一性を判定するかを決定する。

本実施例では、

「表層格の差異を無視する」、

「付属語情報の差異を無視する」

と動作を制御するように類似構造判定調整手段26が指定を行ったため、頻出類似パターン検出手段24は、前記第2の実施例と同様に、類似構造の同一性の判定を行う。

本実施例においては、図23、図24、及び図29を参照すると、

「類似構造1a-1、及び、類似構造2a-3」、

「部分構造2c-0、及び、部分構造3b-0」、

「類似構造1b-1、類似構造2c-1、及び、類似構造3b-1」、

「部分構造1c-0、及び、類似構造2b-0」、

「類似構造1c-1、及び、類似構造2b-1」、

「部分構造 1 d - 0、及び、部分構造 2 d - 0」、
「部分構造 1 e - 0、部分構造 2 f - 0、及び、部分構造 3 f - 0」、
「部分構造 1 f - 0、部分構造 2 e - 0、及び、部分構造 3 d - 0」
がそれぞれ頻出類似パターン検出手段 24 に同一の構造と判定される。
頻出類似パターン検出手段 24 は、要素の少なくとも一つが同一である同値類は
同一と判定するため、

「同値類 1 a、及び、2 a」、
「同値類 1 b、2 c、及び、3 b」、
「同値類 1 c、及び、2 b」、
「同値類 1 d、及び、2 d」、
「同値類 1 e、2 f、及び、3 f」、
「同値類 1 f、2 e、及び、3 d」

をそれぞれ同一の同値類と判定する。
本実施例では、前記第 1、第 2 の実施例と同様に、3 回以上出現する同値類を頻
出パターンとする。

この場合、

「同値類 1 b、2 c、及び、3 b」、
「同値類 1 e、2 f、及び、3 f」、
「同値類 1 f、2 e、及び、3 d」
が頻出パターンとして検出される。

最後に、このようにして抽出された頻出パターンを表す構造を、出力装置 3 に表
示する（図 12 のステップ A4）。

本実施例において、出力装置 3 が output する頻出パターンの表現は、図 30 のよう
になる。図 30 に示すように、本実施例では、前記第 1、第 2 の実施例と同様に、
頻出パターンを表す同値類の要素である類似構造を頻出パターンの表現として用
いている。

使用者は、この頻出パターン検出に不満を感じた場合、図 12 のステップ C1 に
戻り、どこまで類似した構造を同一と判定するかの指定の入力を変更することで、
再度頻出パターンの検出を行うことができる。

このようにして、

「同義語の置換による差異については同一と判定しない」

という使用者の指定に基づき、図23、図24、図29において、

「部分構造1a-0、部分構造2a-0、及び、部分構造3a-0」、

「部分構造1c-0、部分構造2b-0、及び、部分構造3c-0」、

「部分構造1d-0、部分構造2d-0、及び、部分構造3e-0」

といった類似した意味を持つが使用者の入力に反する構造を同一と判定せずに、頻出パターン検出行うことで、使用者がどこまで類似した構造を同一と判定するかの調整を行うことができる。

本発明によれば、連結構造は異なるが類似した意味を持つ構造を同一の構造と判定して頻出パターンを検出することができる。本発明によれば、属性値を持たない構造の集合に対して類似構造を同一と判定して頻出パターンの検出を行うことができる。

その理由は、本発明においては、生成した類似構造を元の構造の同値類として扱い、頻出パターン検出を行う構成としたためである。本発明によれば、属性値を持つ構造の集合に対しても類似構造を同一と判定して頻出パターンの検出を行うことができる。

また、本発明によれば、類似した意味を持つが異なる属性値を持つ構造を同一の構造と判定して頻出パターンを検出することができる。

その理由は、本発明においては、頻出類似パターン検出手段が属性値の差異を無視して頻出パターン検出を行うためである。

さらに本発明によれば、テキストマイニング装置の使用者がどこまで類似した構造を同一な構造と判定して頻出パターン検出を行うかを調整することができる。

その理由は、本発明においては、類似構造生成調整手段と類似構造判定調整手段が使用者からの入力に基づき、どこまで類似した構造を同一な構造と判定するかの調整を行う構成としたためである。

産業上の利用可能性

本発明によれば、コンピュータ上に蓄積される、顧客からの苦情メールやアンケ

ート結果の特徴分析を行う目的に良く用いられるテキストマイニング装置や、テキストマイニング装置をコンピュータに実現するためのプログラムといった用途に適用できる。

請 求 の 範 囲

1. 入力した文書から文構造を作成する手段と、

前記文構造の部分構造に対して、予め定められた所定の変換操作を行うことで、
前記部分構造と意味の類似したパターンの類似構造を作成する手段と、

前記意味の類似したパターンを同一パターンと判定してパターン検出を行う手
段と、

を備えていることを特徴とするテキストマイニング装置。

2. テキストマイニングの対象となる文書の集まりを記憶する記憶部と、

前記記憶部の前記文書を入力して解析し文構造を取得する解析部と、

を備え、

前記解析部は、前記文書を解析し、文節が節点をなし、少なくとも係り受け関係
を係り元の節点から係り先への節点の有向枝で表わした文構造を生成する、

ことを特徴とする請求項 1 に記載のテキストマイニング装置。

3. 前記類似構造を生成する手段が、

前記文構造について並列変形を行う手段と、

前記文構造の部分構成を生成する手段と、

前記文構造及び／又は部分構造の有向枝の無向枝化を行う手段と、

同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行う
手段と、

前記文構造及び／又は部分構造における順序木の無順序木化を行う手段と、

を備え、

前記類似構造を前記文構造の部分構造の同値類とする、

ことを特徴とする、請求項 1 に記載のテキストマイニング装置。

4. テキストマイニングの対象となる文書の集まりを記憶する記憶部と、

前記記憶部から前記文書を読み出して解析し文構造を取得する解析部と、
前記解析部により解析して得られる文構造の部分構造に対して予め定められた
所定の変形操作を行い、意味的に類似したパターンの類似構造を生成する類似構造
生成部と、

前記類似構造生成部によって生成された類似構造を、生成元の部分構造の同値類
として扱いパターン検出を行うパターン検出部と、
を備えていることを特徴とするテキストマイニング装置。

5. 前記パターン検出部は、前記類似構造を、生成元の部分構造の同値類として
扱い頻出パターンを検出することを特徴とする請求項4に記載のテキストマイ
ニング装置。

6. 前記類似構造生成部が、
前記文構造について並列変形を行う手段と、
前記文構造の部分構成を生成する手段と、
前記文構造及び／又は部分構造の有向枝の無向枝化を行う手段と、
同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行う
手段と、
前記文構造及び／又は部分構造における順序木の無順序木化を行う手段と、
を備え、
前記文構造の類似構造を生成し、前記類似構造を同値類とする、
ことを特徴とする請求項4に記載のテキストマイニング装置。

7. 使用者がどこまで類似したパターンを同一と判定してパターン検出を行う
か調整する手段を備えていることを特徴とする請求項4に記載のテキストマイ
ニング装置。

8. テキストマイニングの対象となる文書の集まりを記憶する記憶部と、
前記記憶部から前記文書を読み出して解析し文構造を取得する解析部と、

使用者の入力から文構造の差異の種別ごとに同一構造と判定するか否かを指定する第1の指定項目を生成する類似構造生成調整部と、

使用者の入力から属性値の差異の種別ごとに同一構造と判定するか否かを指定する第2の指定項目を生成する類似構造判定調整部と、

前記類似構造生成調整部によって生成された第1の指定項目に従い、前記解析部で得られた文構造の部分構造に対して所定の変換操作を行い、前記部分構造と意味的に類似した類似構造を生成する類似構造生成部と、

前記類似構造生成部によって生成された類似構造を生成元の部分構造の同値類として扱い、前記類似構造判定調整部の第2の指定項目に従い、属性値の差異を無視しながら、頻出パターンの検出を行う類似パターン検出部と、

を備えていることを特徴とするテキストマイニング装置。

9. 前記解析部は、前記文書を解析し、文節が節点をなし、少なくとも係り受け関係を係り元の節点から係り先への節点の有向枝で表わした前記文構造を生成し、

前記属性値は、前記文構造に付加された表層格及び／又は付属語情報を含む、ことを特徴とする請求項8に記載のテキストマイニング装置。

10. 前記類似パターン検出部は、頻出の類似パターンを検出することを特徴とする請求項8に記載のテキストマイニング装置。

11. 前記類似構造生成部が、

前記第1の指定項目に、並列変形の指定がある場合、前記文構造について並列変形を行う手段と、

前記文構造の部分構造を生成する手段と、

前記第1の指定項目に、有向枝の無向枝化の指定がある場合に、前記文構造及び／又は部分構造の有向枝の無向枝化を行う手段と、

前記第1の指定項目に、同義語の置換の指定がある場合、同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行う手段と、

前記第1の指定項目に、順序木の無順序木化の指定がある場合、前記文構造及び／又は部分構造における順序木の無順序木化を行う手段と、
を備え、

前記文構造の類似構造を生成し、前記類似構造を同値類とする、
ことを特徴とする請求項8に記載のテキストマイニング装置。

12. 入力した文書から文構造を作成する工程と、
前記文構造の部分構造に対する所定の変換操作を行うことで、前記部分構造と意味の類似したパターンの類似構造を作成する工程と、
前記意味の類似したパターンを同一パターンと判定してパターン検出を行う工程と、
を含むことを特徴とするテキストマイニング方法。

13. テキストマイニングの対象となる文書の集まりを記憶する記憶部から前記文書を入力して解析し、文節が節点をなし、少なくとも係り受け関係を係り元の節点から係り先への節点の有向枝で表わした文構造を生成する工程を含むことを特徴とする請求項12に記載のテキストマイニング方法。

14. 前記類似構造を生成する工程が、
前記文構造について並列変形を行う工程と、
前記文構造の部分構造を生成する工程と、
前記文構造及び／又は部分構造の有向枝の無向枝化を行う工程と、
同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行う工程と、
前記文構造及び／又は部分構造における順序木の無順序木化を行う工程と、
を含み、
前記類似構造を前記部分構造の同値類とする、
ことを特徴とする請求項12に記載のテキストマイニング方法。

15. テキストマイニングの対象となる文書の集まりを記憶する記憶部より前記文書を解析して文構造を取得する工程と、

前記文構造の部分構造に対して予め定められた所定の変形操作を行い、意的的に類似したパターンを有する類似構造を生成する工程と、

前記生成された類似構造を、生成元の部分構造の同値類として扱いパターン検出を行う工程と、

を含むことを特徴とするテキストマイニング方法。

16. 前記類似構造を、生成元の部分構造の同値類として扱い頻出パターンを検出する工程を含むことを特徴とする請求項15に記載のテキストマイニング方法。

17. 前記類似構造を生成する工程が、

前記文構造について並列変形を行う工程と、

前記文構造の部分構造を生成する工程と、

前記文構造及び／又は部分構造の有向枝の無向枝化を行う工程と、

同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行う工程と、

前記文構造及び／又は部分構造における順序木の無順序木化を行う工程と、

を含み、

前記文構造の類似構造を生成し、前記類似構造を同値類とすること、

を特徴とする請求項15に記載のテキストマイニング方法。

18. 使用者がどこまで類似したパターンを同一と判定してパターン検出を行うか調整する工程を備えていることを特徴とする請求項17に記載のテキストマイニング方法。

19. テキストマイニングの対象となる文書の集まりを記憶する記憶部より前記文書を解析して文構造を取得する工程と、

使用者の入力から文構造の差異の種別ごとに同一構造と判定するか否かを指定する第1の指定項目を生成する工程と、

使用者の入力から属性値の差異の種別ごとに同一構造と判定するか否かを指定する第2の指定項目を生成する工程と、

前記生成された第1の指定項目に従い、前記解析部で得られた文構造の部分構造に対して所定の変形操作を行い、前記部分構造と意味的に類似した類似構造を生成する工程と、

前記生成された類似構造を生成元の部分構造の同値類として扱い、前記第2の指定項目に従い、属性値の差異を無視してパターンの検出を行う工程と、

を含むことを特徴とするテキストマイニング方法。

20. 前記文構造を取得する工程が、文節が節点をなし、少なくとも係り受け関係を係り元の節点から係り先への節点の有向枝で表わした前記文構造を生成し、

前記属性値は、前記文構造に付加された表層格及び／又は付属語情報を含む、

ことを特徴とする請求項19に記載のテキストマイニング方法。

21. 前記頻出の類似パターンを検出することを特徴とする請求項19に記載のテキストマイニング方法。

22. 前記類似構造を生成する工程が、

前記第1の指定項目に、並列変形の指定がある場合、前記文構造について並列変形を行う工程と、

前記文構造の部分構造を生成する工程と、

前記第1の指定項目に、有向枝の無向枝化の指定がある場合に、前記文構造及び／又は部分構造の有向枝の無向枝化を行う工程と、

前記第1の指定項目に、同義語の置換の指定がある場合、同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行う工程と、

前記第1の指定項目に、順序木の無順序木化の指定がある場合、前記文構造及び／又は部分構造における順序木の無順序木化を行う工程と、

を含み、

前記文構造の類似構造を生成し、前記類似構造を同値類とする、ことを特徴とする、請求項 1 9 に記載のテキストマイニング方法。

23. テキストマイニング装置を構成するコンピュータに、

テキストマイニングの対象となる文書の集まりを記憶する記憶部の前記文書を解析して文構造を取得する処理と、

前記文構造の部分構造に対して所定の変換操作を行い、前記部分構造と意味的に類似した類似構造を生成する処理と、

前記生成された類似構造を、生成元の部分構造の同値類として扱い、所定のパターン検出を行う処理と、

を実行させるプログラム。

24. テキストマイニング装置を構成するコンピュータに、

テキストマイニングの対象となる文書の集まりを記憶する記憶部の前記文書を解析して文構造を取得する処理と、

前記文構造の部分構造に対して予め定められた所定の変換操作を行い、前記部分構造と意味的に類似したパターンの類似構造を生成する処理と、

前記生成された類似構造を生成元の部分構造の同値類として扱い、属性値の差異を無視しながらパターン検出を行う処理と、

を実行させるプログラム。

25. テキストマイニング装置を構成するコンピュータに、

テキストマイニングの対象となる文書の集まりを記憶する記憶部の前記文書を解析して文構造を取得する処理と、

使用者の入力から、前記文構造の差異の種別ごとに、同一構造と判定するか否かを指定する第 1 の指定項目と、属性値の差異の種別ごとに同一構造と判定するか否かを指定する第 2 の指定項目を生成する処理と、

前記文構造の差異の種別ごとに同一構造と判定するか否かを指定する前記第 1

の指定項目に従って、前記文構造の部分構造に対して所定の変換操作を行い、意味的に類似したパターンの類似構造を生成する処理と、

生成された類似構造を生成元の部分構造の同値類として扱い、属性値の差異の種別ごとに同一構造と判定するか否かを指定する前記第2の指定項目に従って、属性値の差異を無視しながら頻出パターンの検出を行う処理と

を実行させるプログラム。

補正書の請求の範囲

[2005年7月15日 (15.07.2005) 国際事務局受理：出願当初の請求の範囲 1、4、12、15、23及び24は補正された；他の請求の範囲は変更なし。(5頁)]

1. (補正後) 入力した文書から文構造を作成する手段と、

前記文構造の部分構造に対して、少なくともグラフ構造の枝の繋ぎ替えを含む、予め定められた所定の変換操作を行うことで、前記部分構造と意味の類似したパターンの類似構造を生成する手段と、

前記意味の類似したパターンを同一パターンと判定してパターン検出を行う手段と、

を備えていることを特徴とするテキストマイニング装置。

2. テキストマイニングの対象となる文書の集まりを記憶する記憶部と、

前記記憶部の前記文書を入力して解析し文構造を取得する解析部と、
を備え、

前記解析部は、前記文書を解析し、文節が節点をなし、少なくとも係り受け関係を係り元の節点から係り先への節点の有向枝で表わした文構造を生成する、

ことを特徴とする請求項1に記載のテキストマイニング装置。

3. 前記類似構造を生成する手段が、

前記文構造について並列変形を行う手段と、

前記文構造の部分構成を生成する手段と、

前記文構造及び／又は部分構造の有向枝の無向枝化を行う手段と、

同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行う手段と、

前記文構造及び／又は部分構造における順序木の無順序木化を行う手段と、

を備え、

前記類似構造を前記文構造の部分構造の同値類とする、

ことを特徴とする、請求項1に記載のテキストマイニング装置。

4. (補正後) テキストマイニングの対象となる文書の集まりを記憶する記憶部と、

前記記憶部から前記文書を読み出して解析し文構造を取得する解析部と、
前記解析部により解析して得られる文構造の部分構造に対して、少なくともグラ
フ構造の枝の繋ぎ替えを含む、予め定められた所定の変換操作を行い、意的的に類
似したパターンの類似構造を生成する類似構造生成部と、
前記類似構造生成部によって生成された類似構造を、生成元の部分構造の同値類
として扱いパターン検出を行うパターン検出部と、
を備えていることを特徴とするテキストマイニング装置。

5. 前記パターン検出部は、前記類似構造を、生成元の部分構造の同値類とし
て扱い頻出パターンを検出することを特徴とする請求項4に記載のテキストマイ
ニング装置。

6. 前記類似構造生成部が、
前記文構造について並列変形を行う手段と、
前記文構造の部分構成を生成する手段と、
前記文構造及び／又は部分構造の有向枝の無向枝化を行う手段と、
同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行
う手段と、
前記文構造及び／又は部分構造における順序木の無順序木化を行う手段と、
を備え、
前記文構造の類似構造を生成し、前記類似構造を同値類とする、
ことを特徴とする請求項4に記載のテキストマイニング装置。

7. 使用者がどこまで類似したパターンを同一と判定してパターン検出を行
うか調整する手段を備えていることを特徴とする請求項4に記載のテキストマイニ
ング装置。

8. テキストマイニングの対象となる文書の集まりを記憶する記憶部と、
前記記憶部から前記文書を読み出して解析し文構造を取得する解析部と、

前記第1の指定項目に、順序木の無順序木化の指定がある場合、前記文構造及び／又は部分構造における順序木の無順序木化を行う手段と、
を備え、

前記文構造の類似構造を生成し、前記類似構造を同値類とする、
ことを特徴とする請求項8に記載のテキストマイニング装置。

12. (補正後) 入力した文書から文構造を作成する工程と、
前記文構造の部分構造に対して、少なくともグラフ構造の枝の繋ぎ替えを含む、
所定の変換操作を行うことで、前記部分構造と意味の類似したパターンの類似構造
を作成する工程と、

前記意味の類似したパターンを同一パターンと判定してパターン検出を行う工
程と、
を含むことを特徴とするテキストマイニング方法。

13. テキストマイニングの対象となる文書の集まりを記憶する記憶部から前
記文書を入力して解析し、文節が節点をなし、少なくとも係り受け関係を係り元の
節点から係り先への節点の有向枝で表わした文構造を生成する工程を含むことを
特徴とする請求項12に記載のテキストマイニング方法。

14. 前記類似構造を生成する工程が、
前記文構造について並列変形を行う工程と、
前記文構造の部分構造を生成する工程と、
前記文構造及び／又は部分構造の有向枝の無向枝化を行う工程と、
同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行
う工程と、

前記文構造及び／又は部分構造における順序木の無順序木化を行う工程と、
を含み、

前記類似構造を前記部分構造の同値類とする、
ことを特徴とする請求項12に記載のテキストマイニング方法。

15. (補正後) テキストマイニングの対象となる文書の集まりを記憶する記憶部より前記文書を解析して文構造を取得する工程と、

前記文構造の部分構造に対して、少なくともグラフ構造の枝の繋ぎ替えを含む、予め定められた所定の変換操作を行い、意味的に類似したパターンを有する類似構造を生成する工程と、

前記生成された類似構造を、生成元の部分構造の同値類として扱いパターン検出を行う工程と、

を含むことを特徴とするテキストマイニング方法。

16. 前記類似構造を、生成元の部分構造の同値類として扱い頻出パターンを検出する工程を含むことを特徴とする請求項15に記載のテキストマイニング方法。

17. 前記類似構造を生成する工程が、

前記文構造について並列変形を行う工程と、

前記文構造の部分構造を生成する工程と、

前記文構造及び／又は部分構造の有向枝の無向枝化を行う工程と、

同義語辞書を参照して前記文構造及び／又は部分構造中の同義語の置換を行う工程と、

前記文構造及び／又は部分構造における順序木の無順序木化を行う工程と、

を含み、

前記文構造の類似構造を生成し、前記類似構造を同値類とすること、

を特徴とする請求項15に記載のテキストマイニング方法。

18. 使用者がどこまで類似したパターンを同一と判定してパターン検出を行うか調整する工程を備えていることを特徴とする請求項17に記載のテキストマイニング方法。

19. テキストマイニングの対象となる文書の集まりを記憶する記憶部より前記文書を解析して文構造を取得する工程と、

を含み、

前記文構造の類似構造を生成し、前記類似構造を同値類とする、ことを特徴とする、請求項 1 9 に記載のテキストマイニング方法。

23. (補正後) テキストマイニング装置を構成するコンピュータに、

テキストマイニングの対象となる文書の集まりを記憶する記憶部の前記文書を解析して文構造を取得する処理と、

前記文構造の部分構造に対して所定の変換操作を行い、少なくともグラフ構造の枝の繋ぎ替えを含む、前記部分構造と意味的に類似した類似構造を生成する処理と、

前記生成された類似構造を、生成元の部分構造の同値類として扱い、所定のパターン検出を行う処理と、

を実行させるプログラム。

24. (補正後) テキストマイニング装置を構成するコンピュータに、

テキストマイニングの対象となる文書の集まりを記憶する記憶部の前記文書を解析して文構造を取得する処理と、

前記文構造の部分構造に対して、少なくともグラフ構造の枝の繋ぎ替えを含む、予め定められた所定の変換操作を行い、前記部分構造と意味的に類似した類似構造を生成する処理と、

前記生成された類似構造を生成元の部分構造の同値類として扱い、属性値の差異を無視しながらパターン検出を行う処理と、

を実行させるプログラム。

25. テキストマイニング装置を構成するコンピュータに、

テキストマイニングの対象となる文書の集まりを記憶する記憶部の前記文書を解析して文構造を取得する処理と、

使用者の入力から、前記文構造の差異の種別ごとに、同一構造と判定するか否かを指定する第 1 の指定項目と、属性値の差異の種別ごとに同一構造と判定するか否かを指定する第 2 の指定項目を生成する処理と、

前記文構造の差異の種別ごとに同一構造と判定するか否かを指定する前記第 1

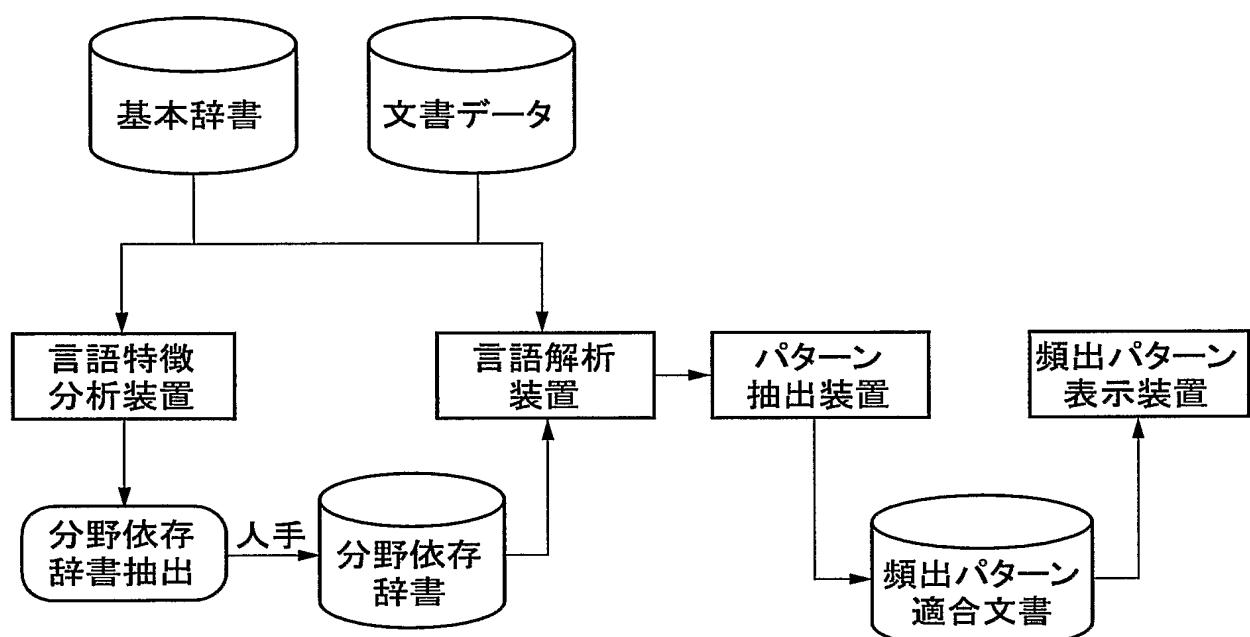


図 1

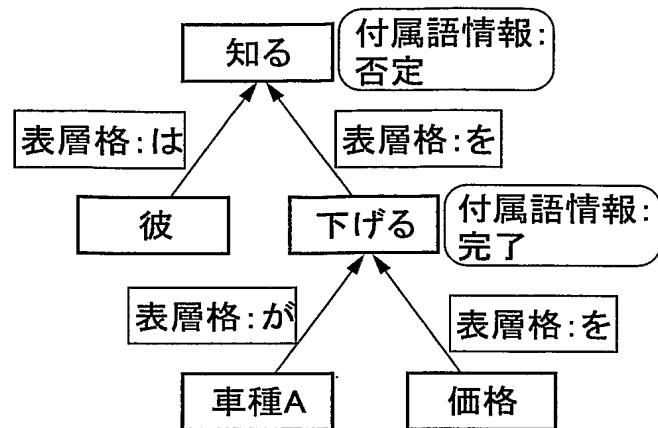


図 2

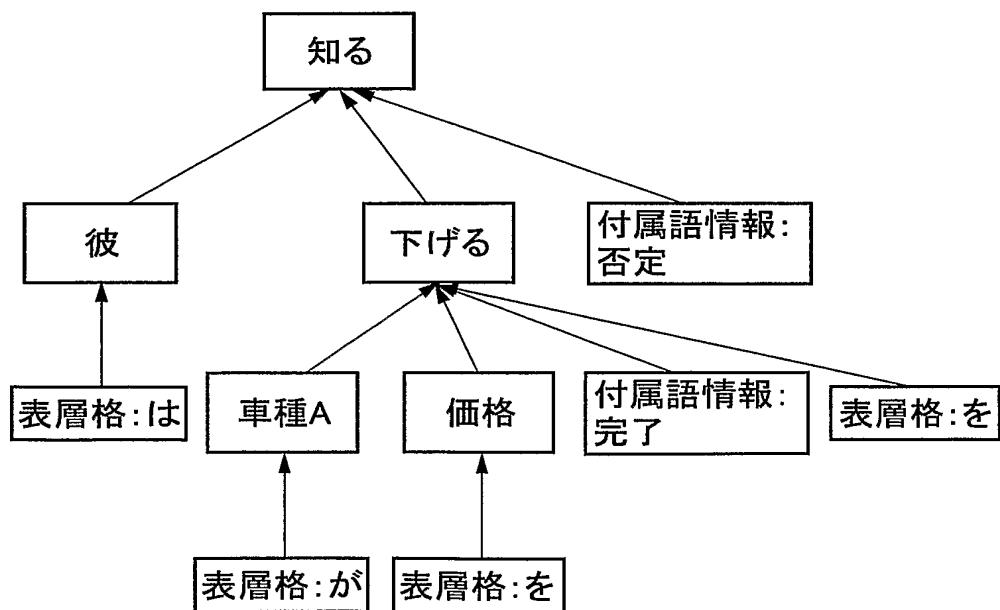


図 3

「速いのは車種A」と
「車種Aは速い」

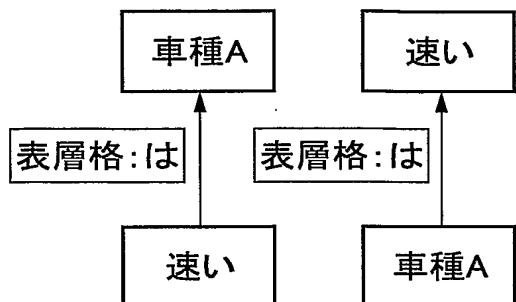


図 4A

「速く安い車種A」と「安く速い車種A」

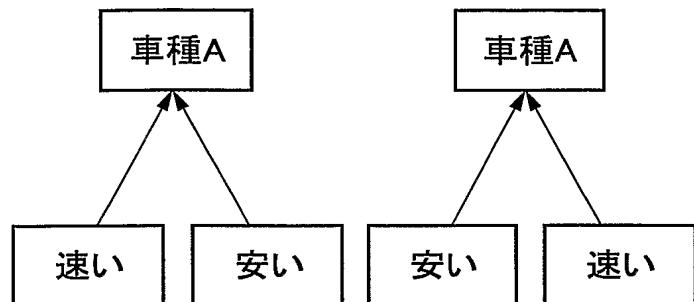


図 4B

「車種Aは加速」と
「車種Aは高速だ」

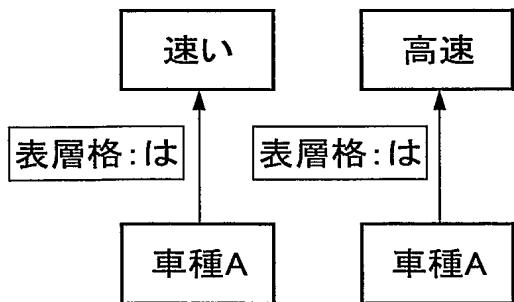


図 4C

「車種Aと車種Bは速い」の
構文構造と意味構造

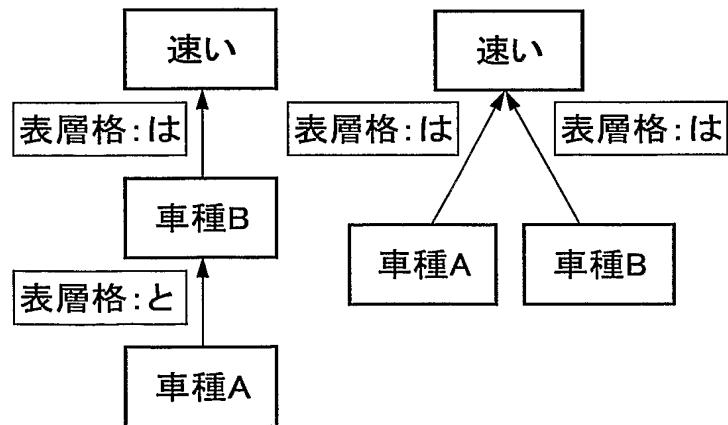


図 4D

「車種Aは加速」と
「車種Aの加速」

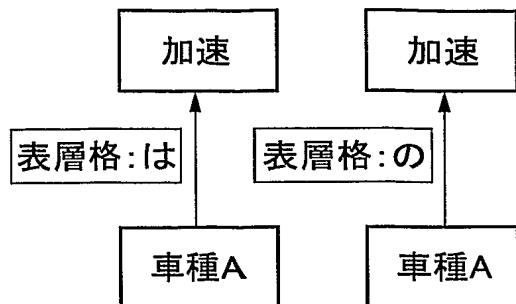


図 5A

「車種Aは速い」と「車種Aは速かった」

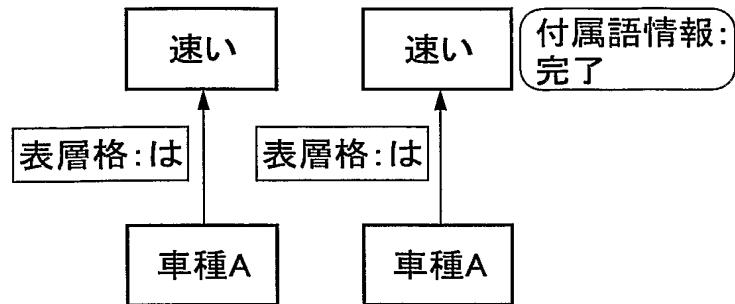


図 5B

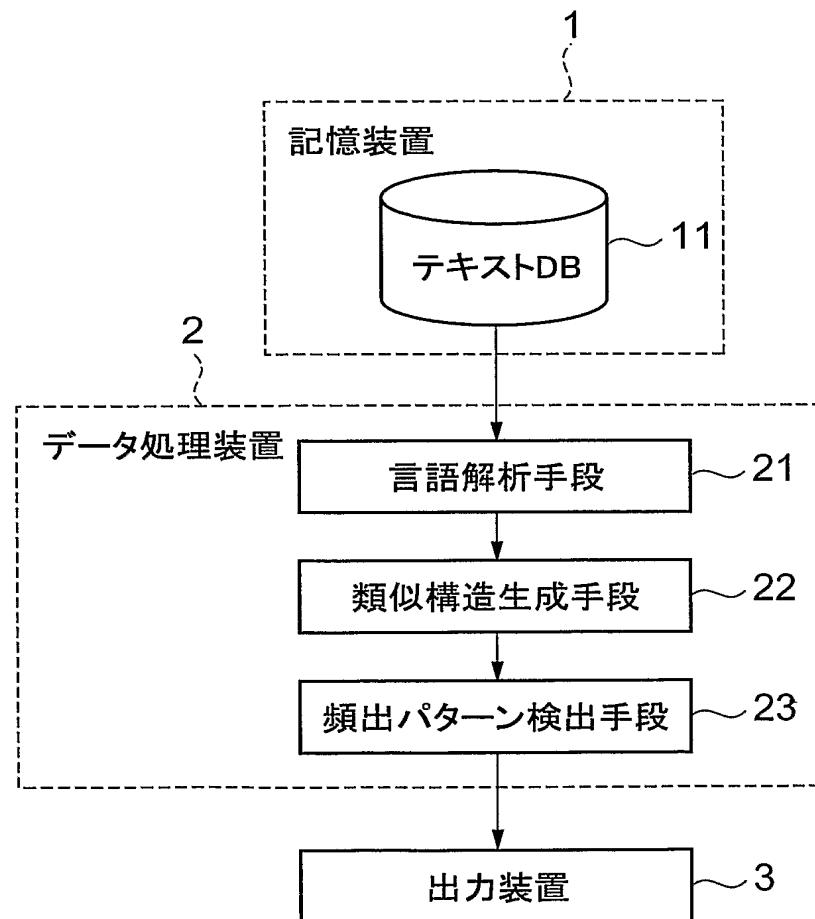


図 6

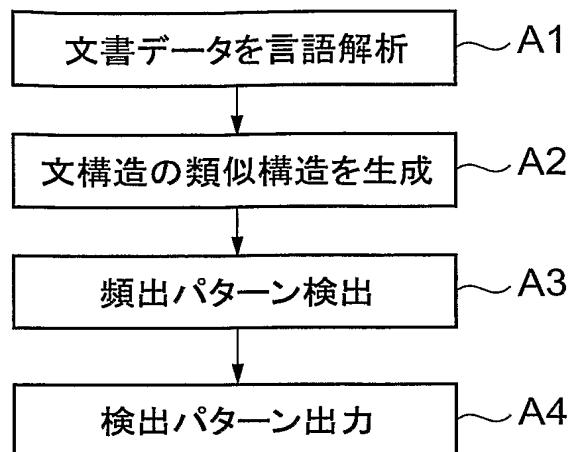


図 7

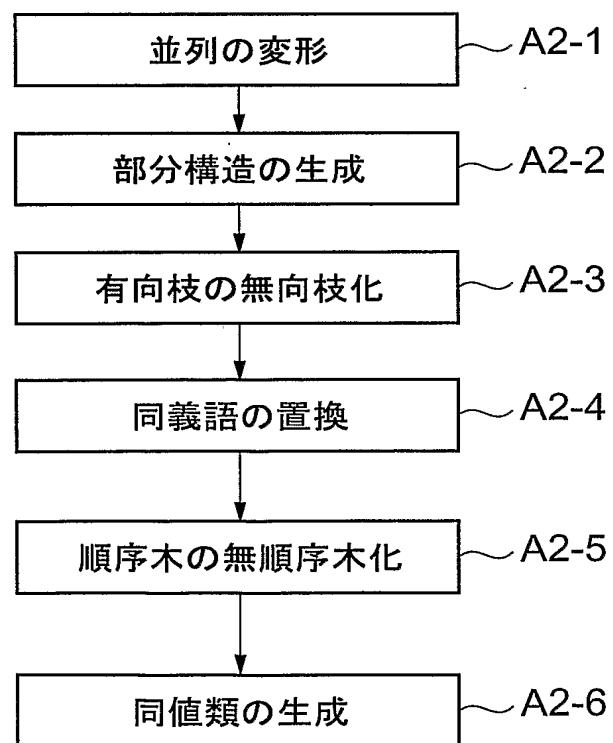


図 8

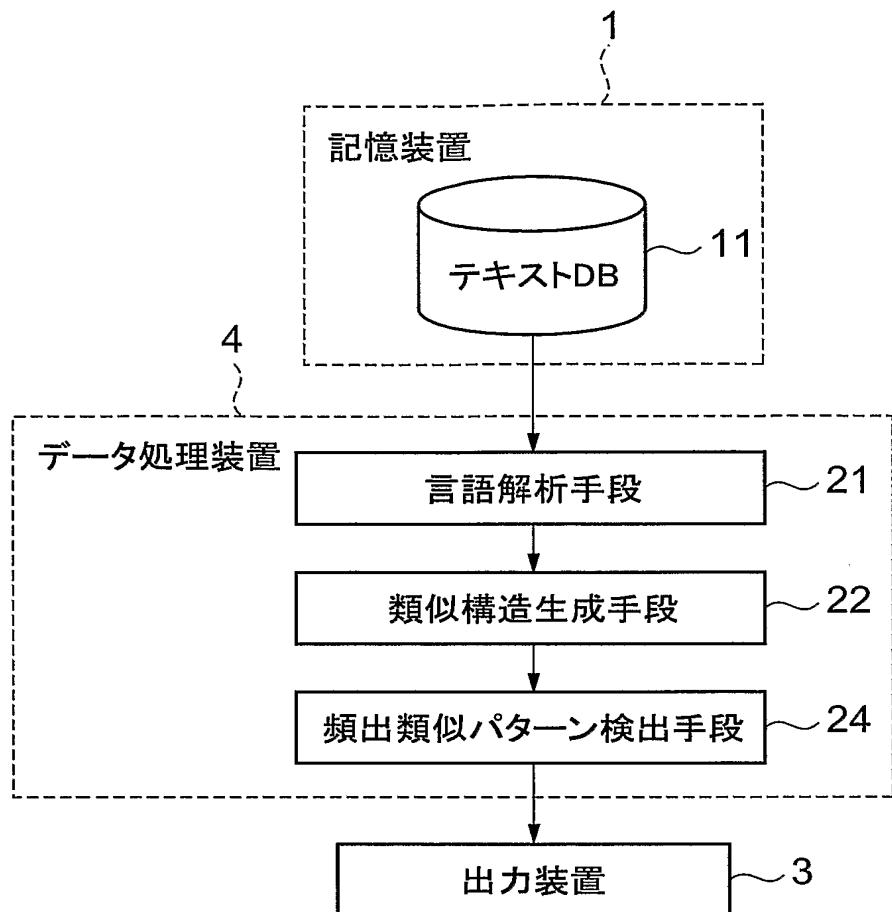


図 9

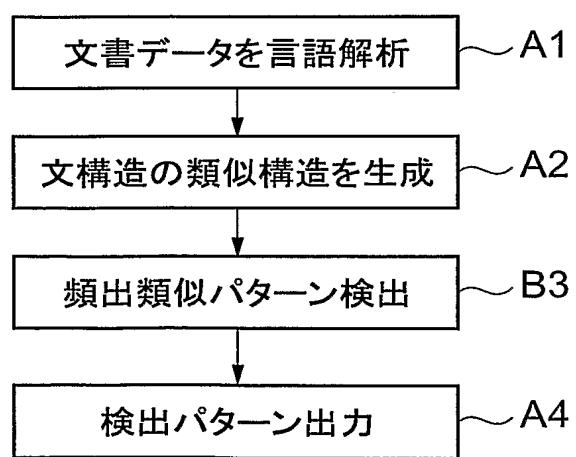


図 10

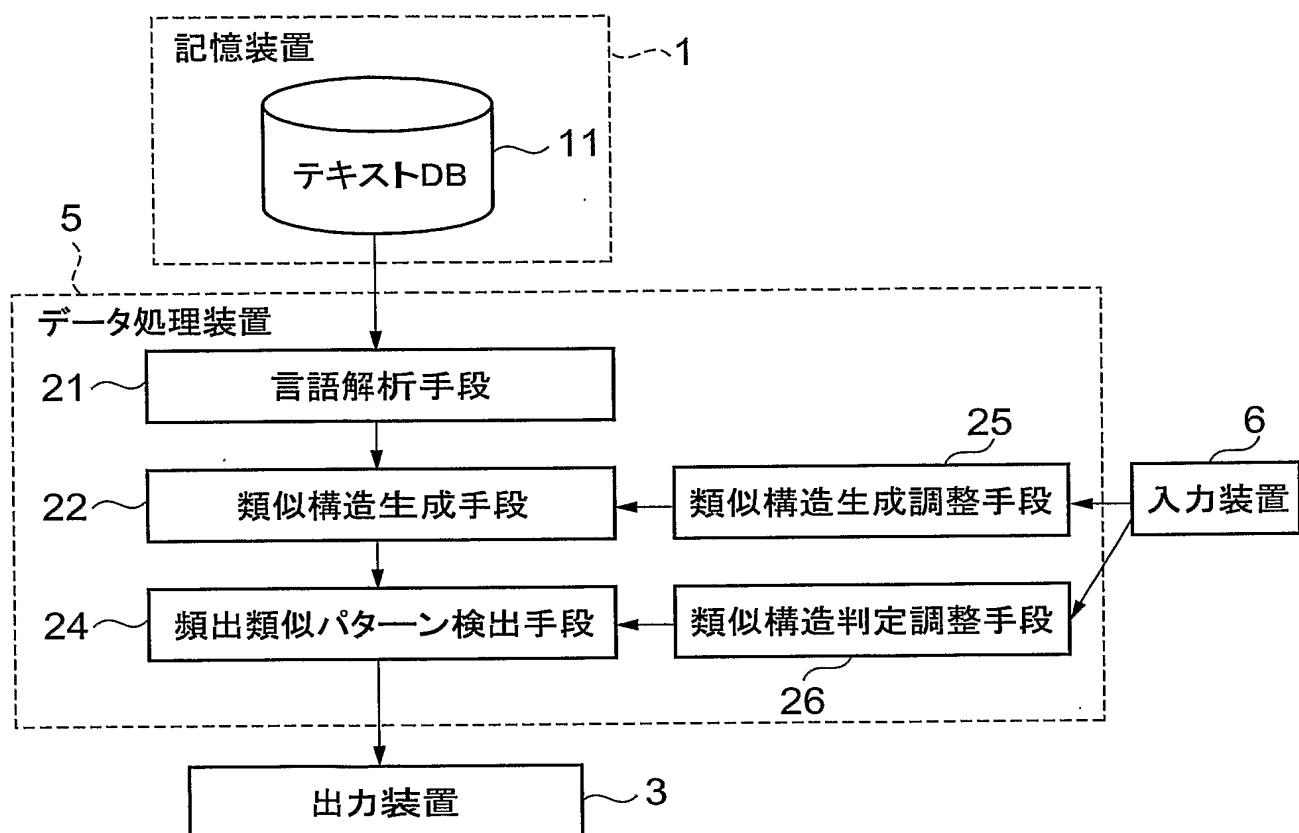


図 11

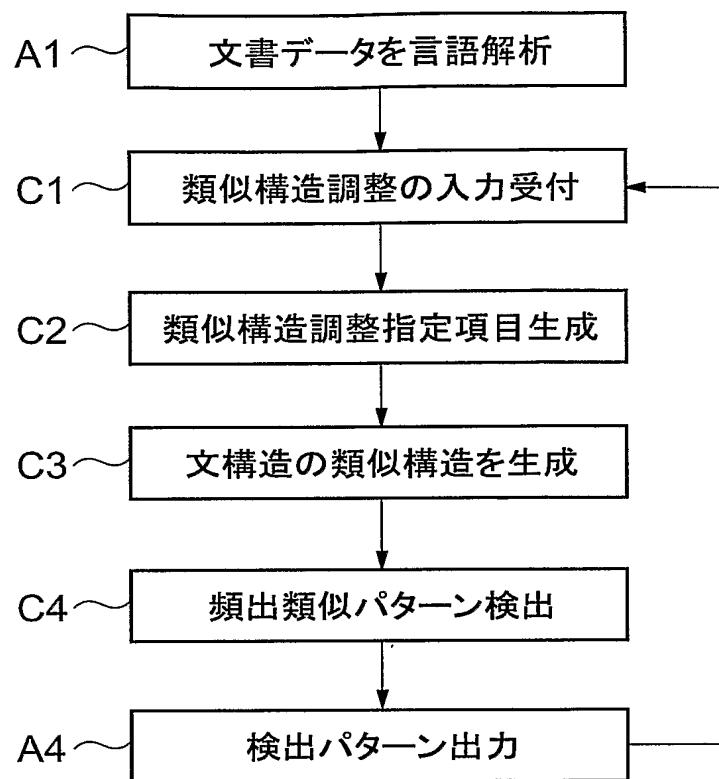


図 12

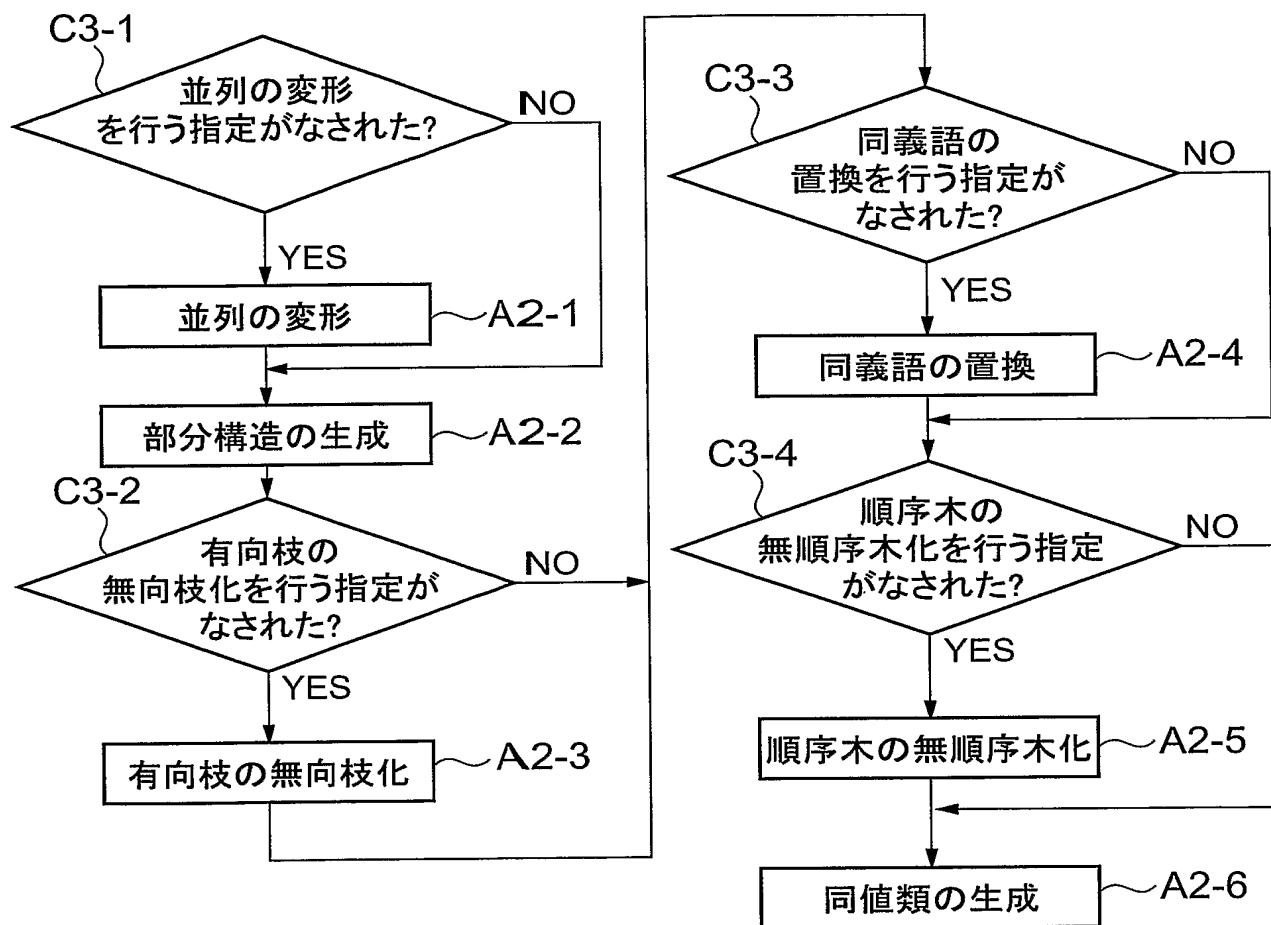


図 13

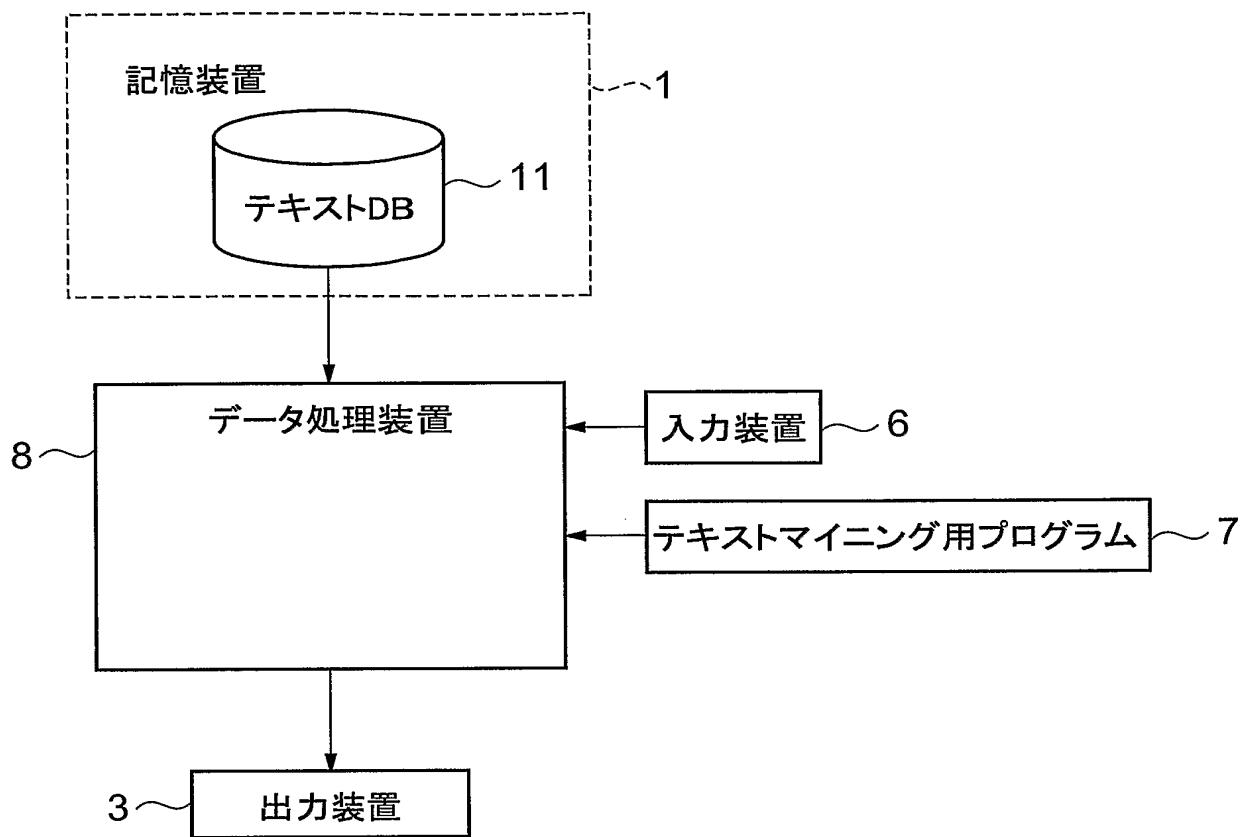
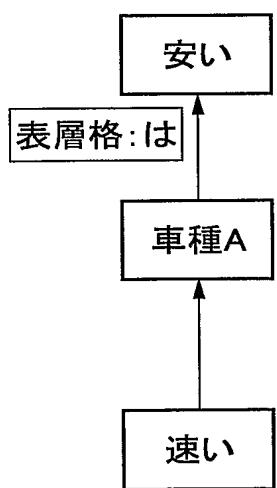


図 14

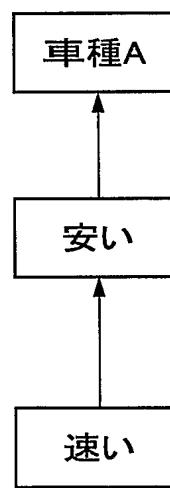
文1: 速い車種Aは安い
 文2: 速く安い車種A
 文3: 安かった高速な車種A

図 15

文1の文構造:



文2の文構造:



文3の文構造:

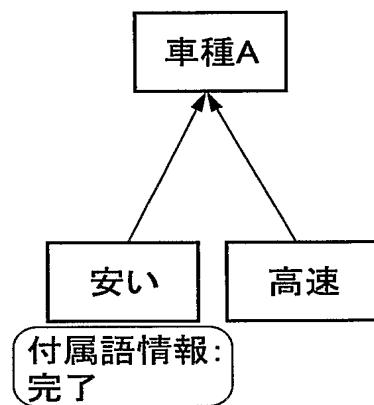


図 16A

図 16B

図 16C

同義語辞書

| 代表語 | 被置換後 |
|-----|------|
| 速い | 高速 |

図 17

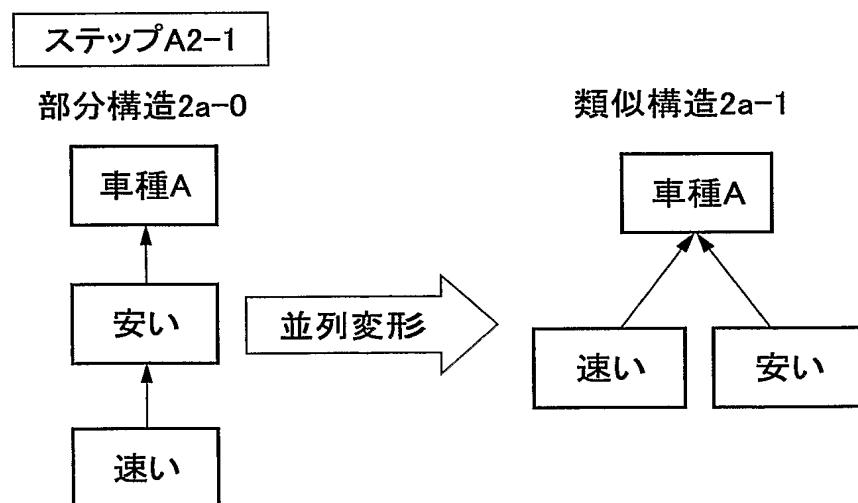


図 18

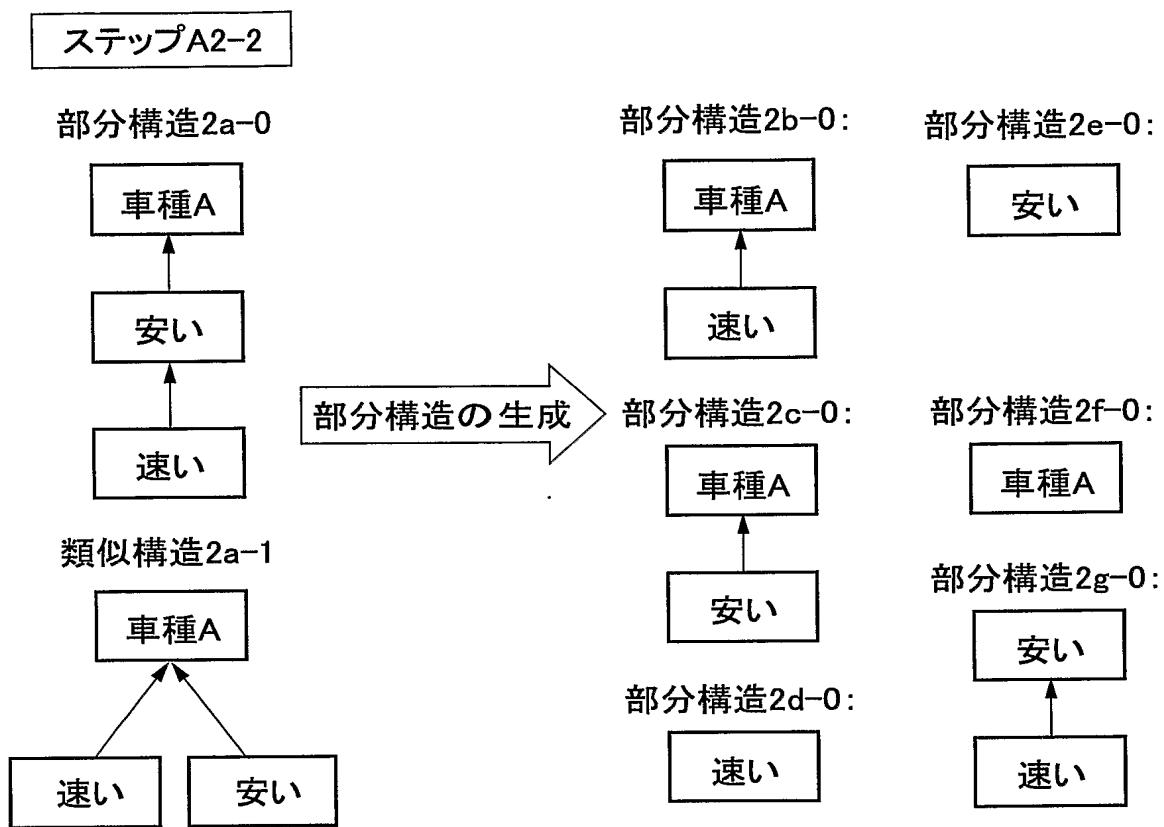
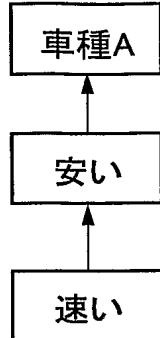


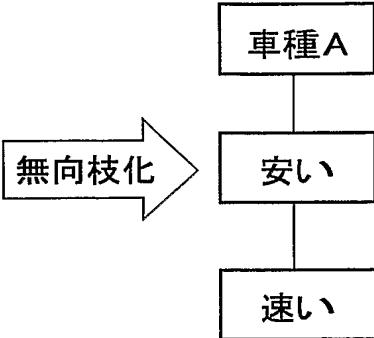
図 19

ステップA2-3

部分構造2a-0



類似構造2a-2



部分構造2c-0:



類似構造2c-1:

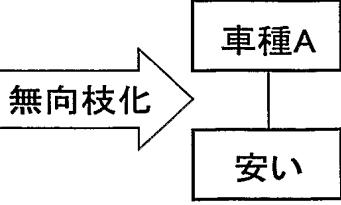
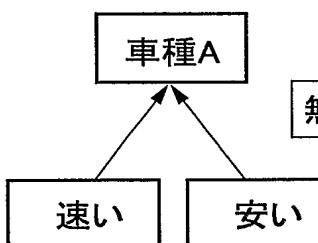


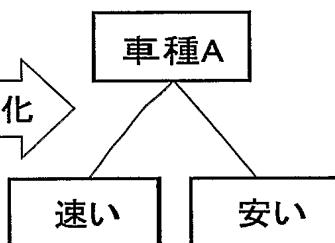
図 20A

図 20B

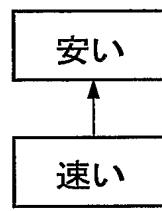
類似構造2a-1



類似構造2a-3



部分構造2g-0:



類似構造2g-1:

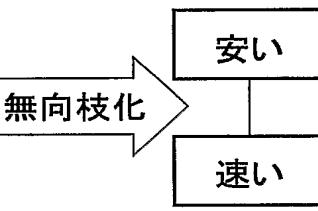
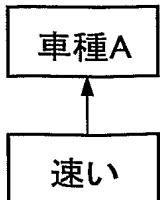


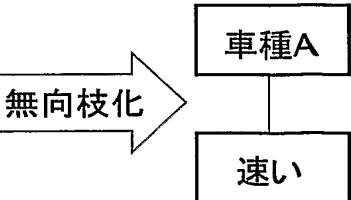
図 20C

図 20D

部分構造2b-0:



類似構造2b-1:

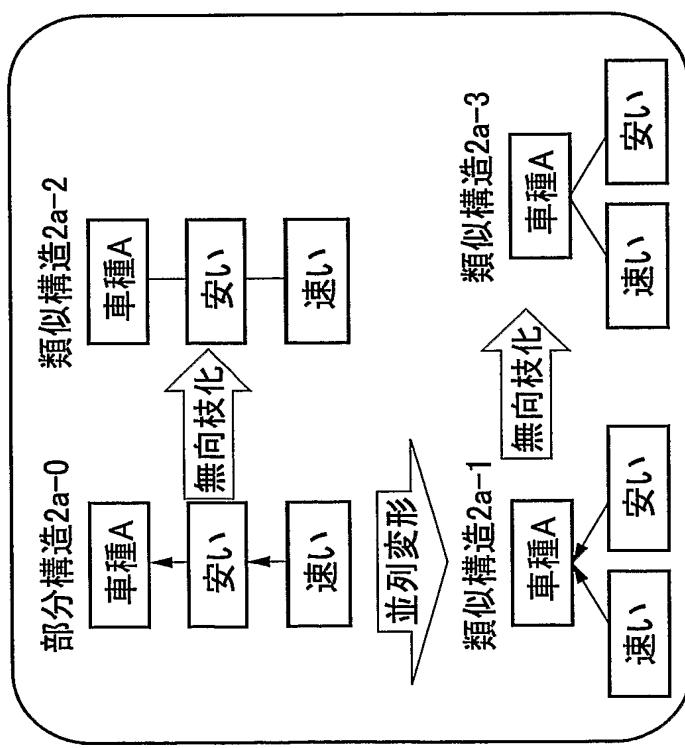


部分構造2d-0,2e-0,2f-0はステップ2A-3では形が変わらないので省略している

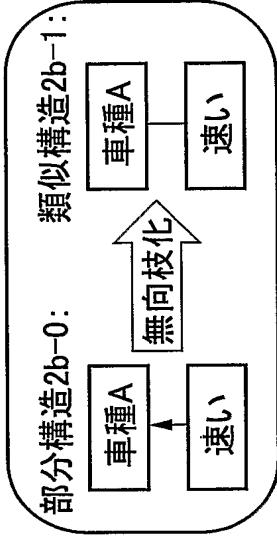
図 20E

ステップA2-6

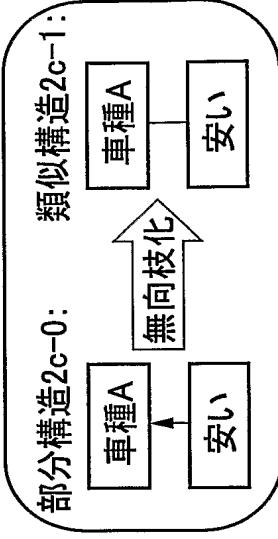
同値類2a:



同値類2b:



同値類2c:



同値類2d: 同値類2e: 同値類2f:

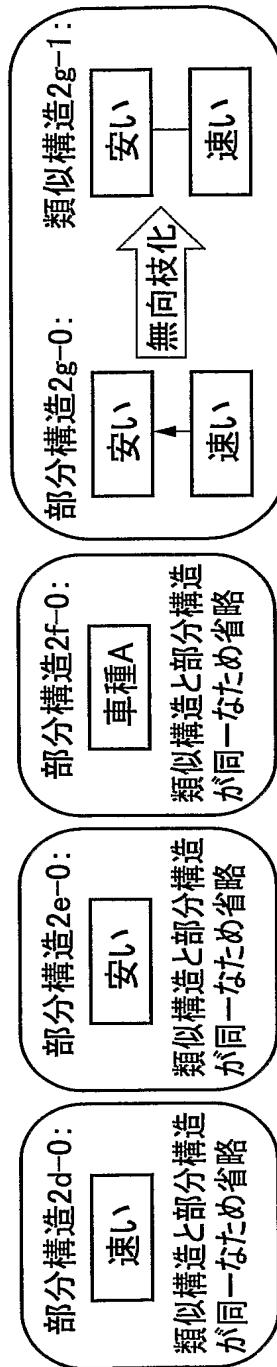


図 21

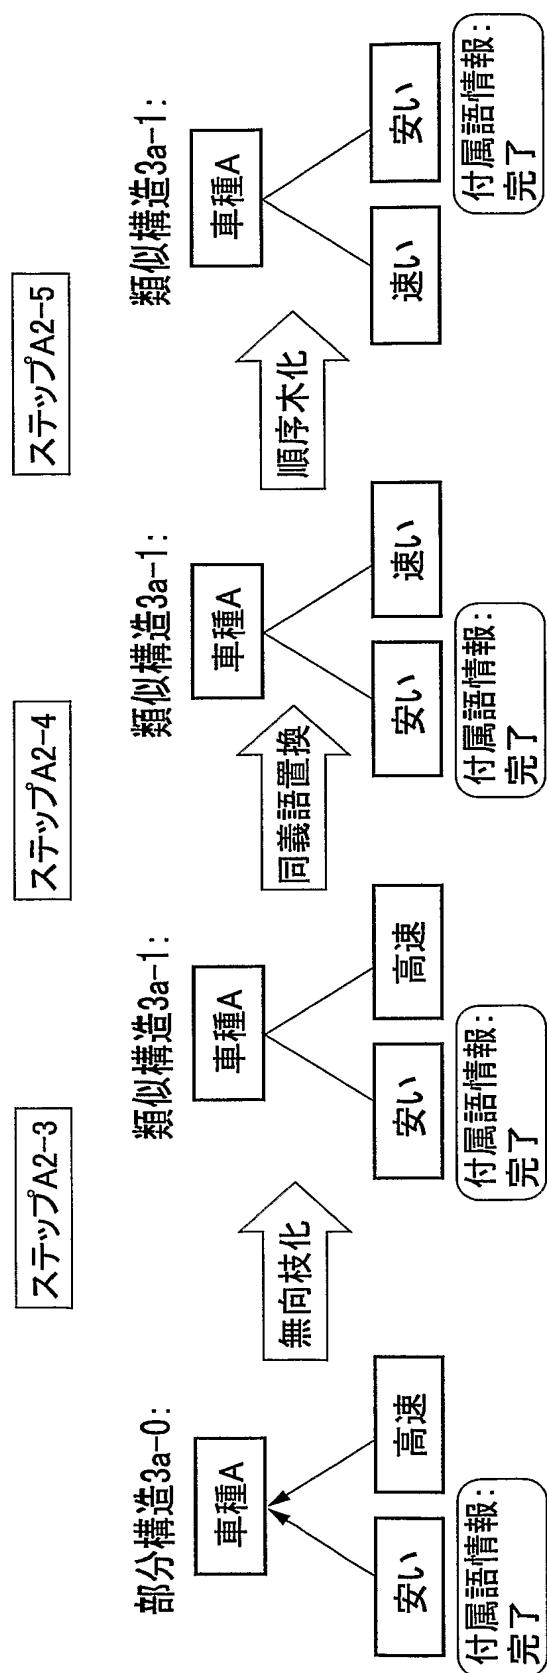


図 22

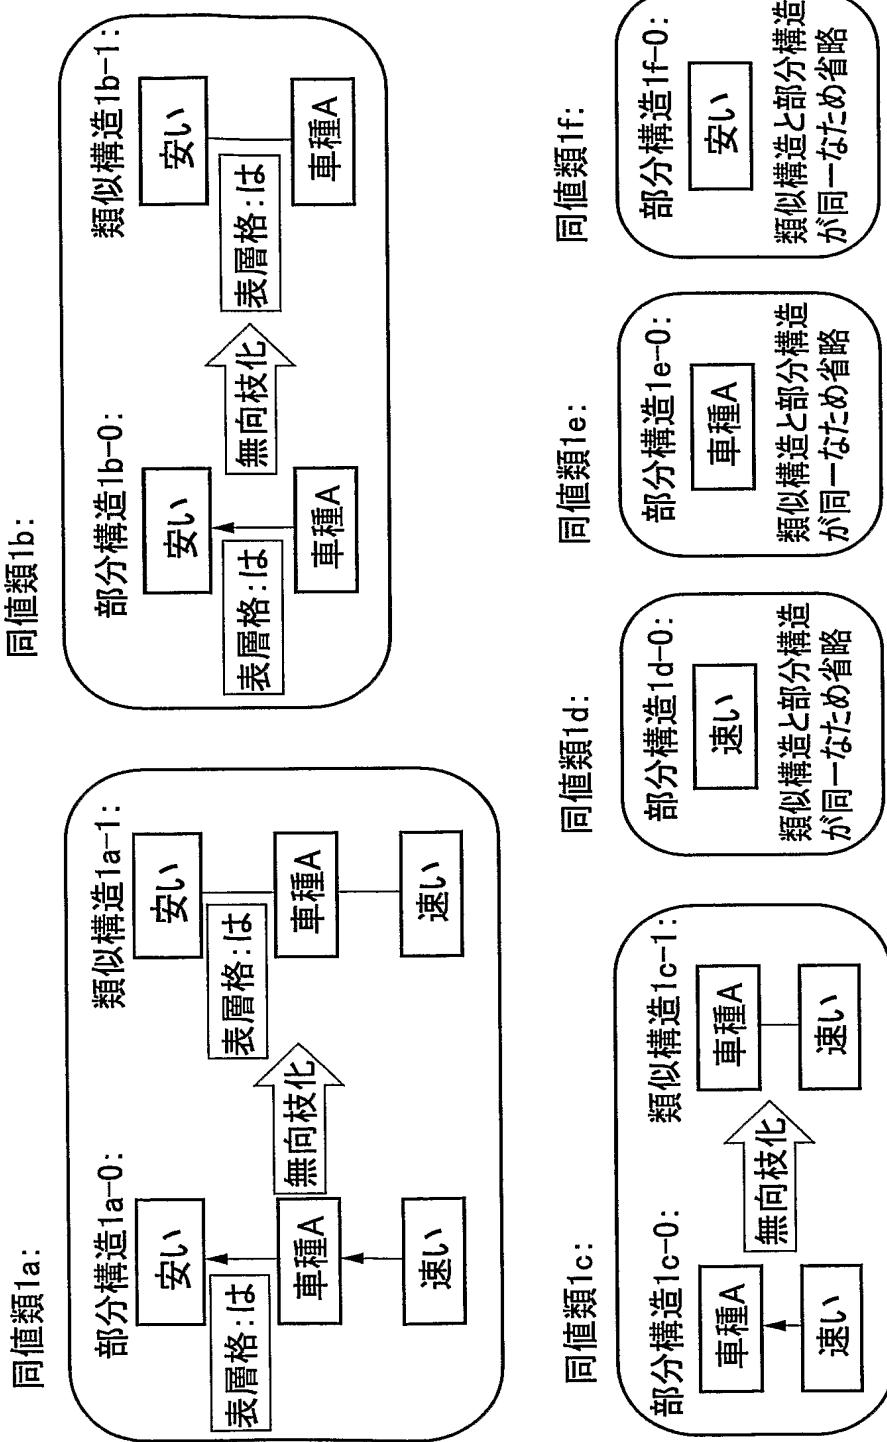


図 23

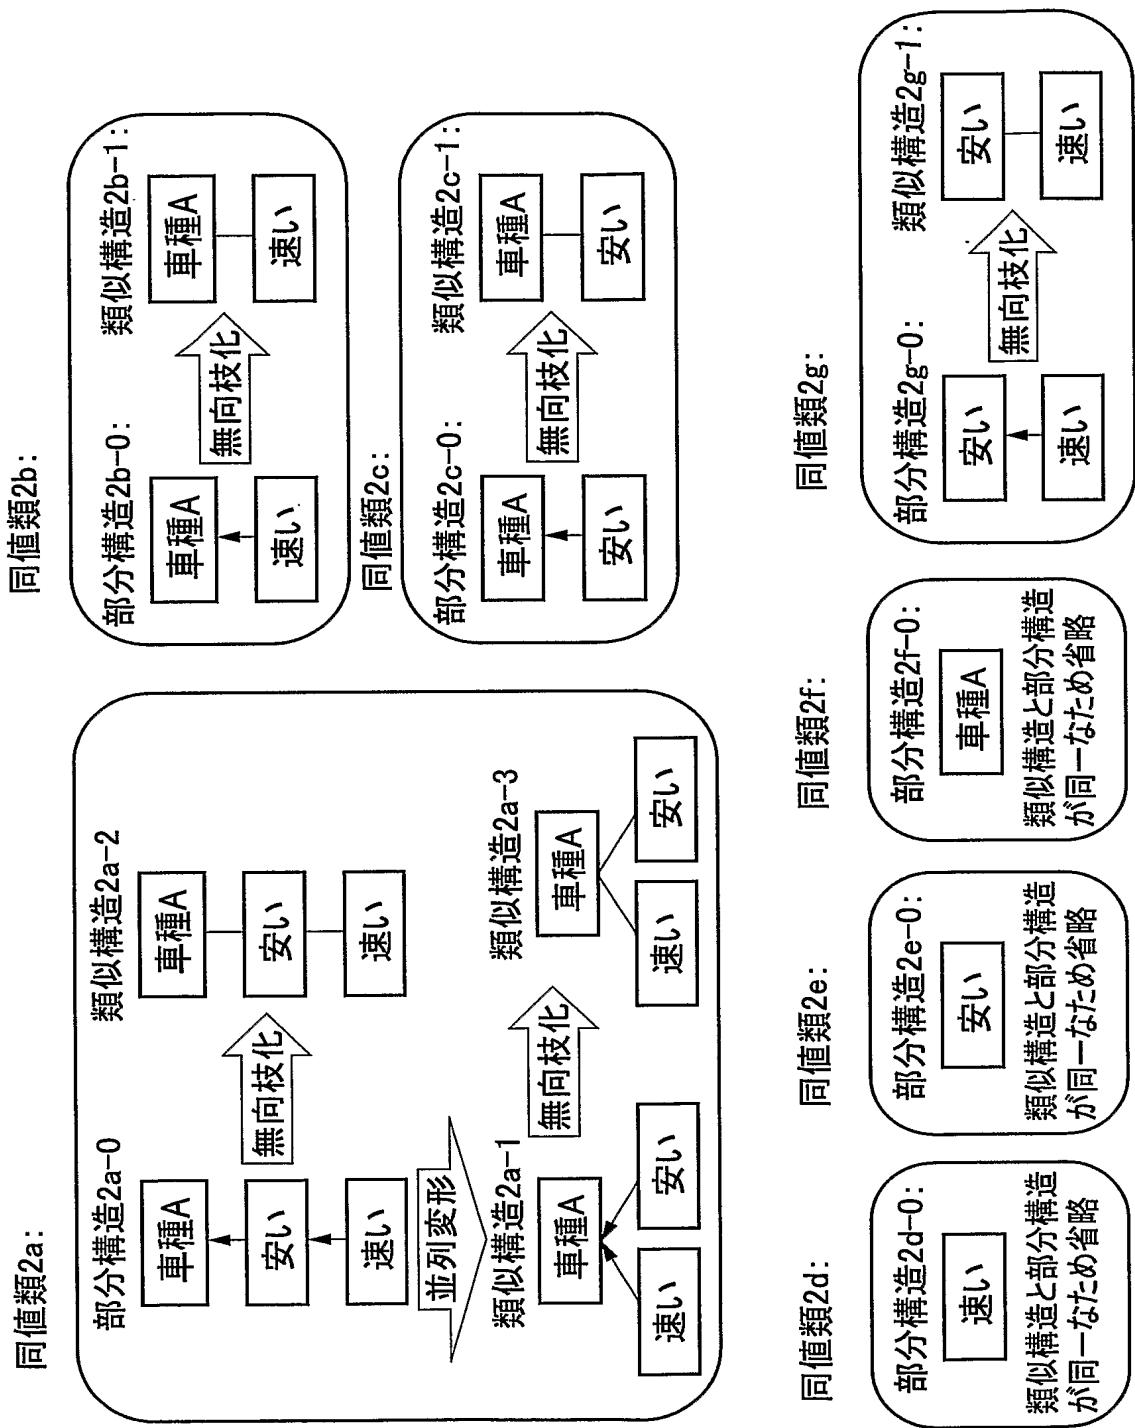
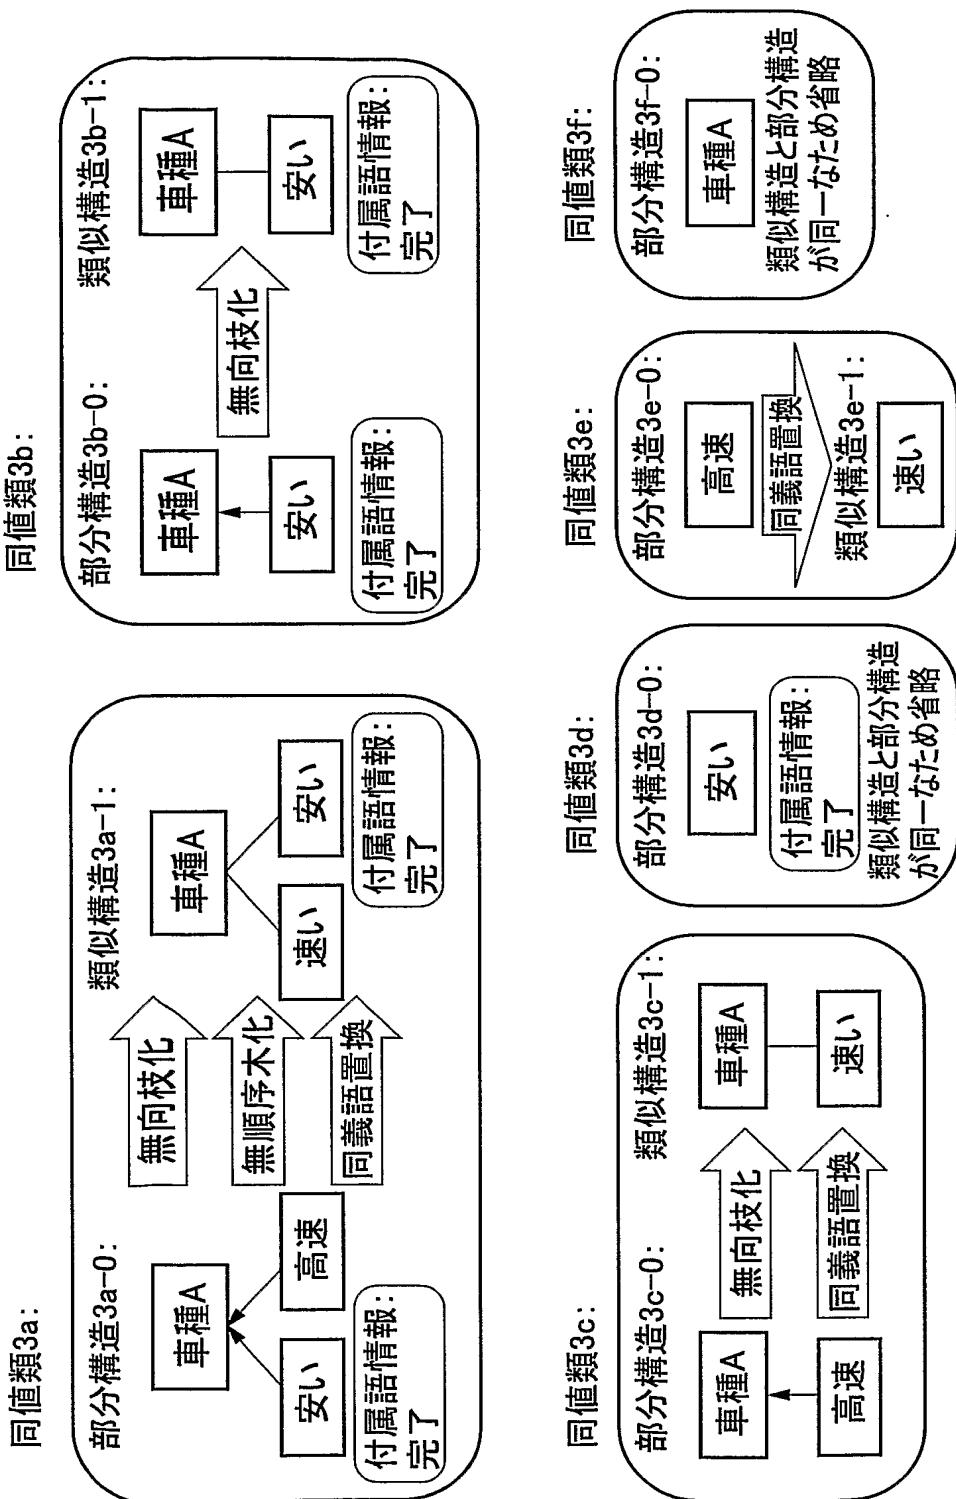
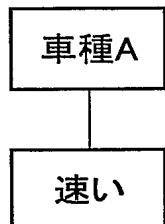


図 24



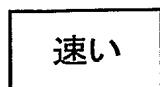
25

頻出パターン1:



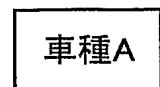
同値類1c,2b,3cから
検出

頻出パターン2:



同値類1d,2d,3eから
検出

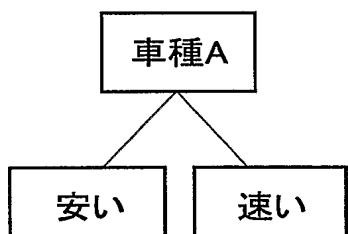
頻出パターン3:



同値類1e,2f,3fから
検出

図 26

頻出パターン1:



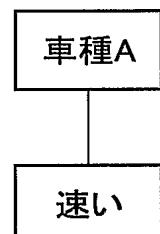
同値類1a,2a,3aから
検出

頻出パターン2:



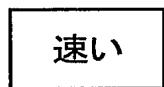
同値類1b,2c,3bから
検出

頻出パターン3:



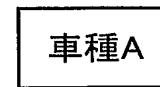
同値類1c,2b,3cから
検出

頻出パターン4:



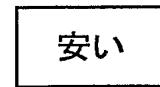
同値類1d,2d,3eから
検出

頻出パターン5:



同値類1e,2f,3fから
検出

頻出パターン6:



同値類1f,2e,3dから
検出

図 27

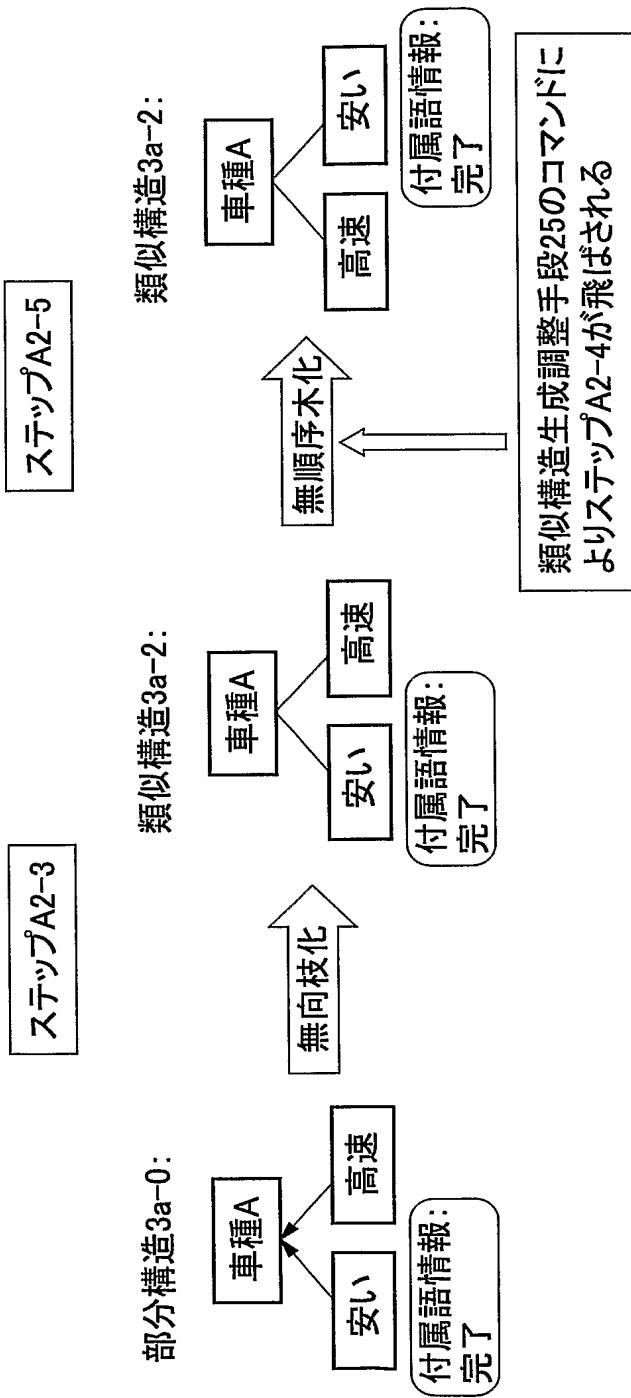


図 28

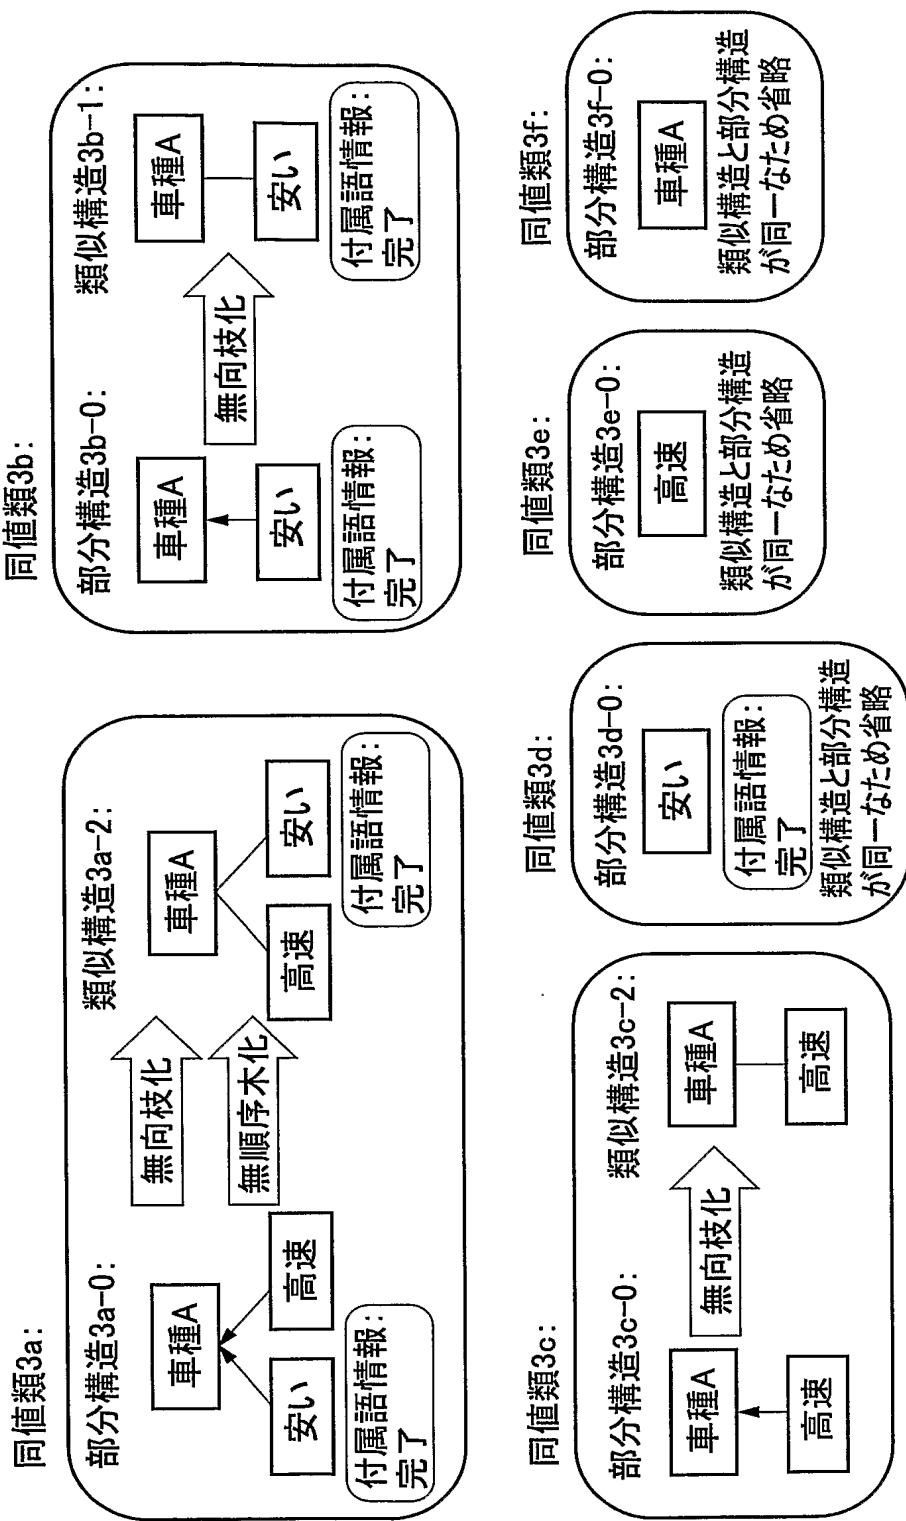


図 29

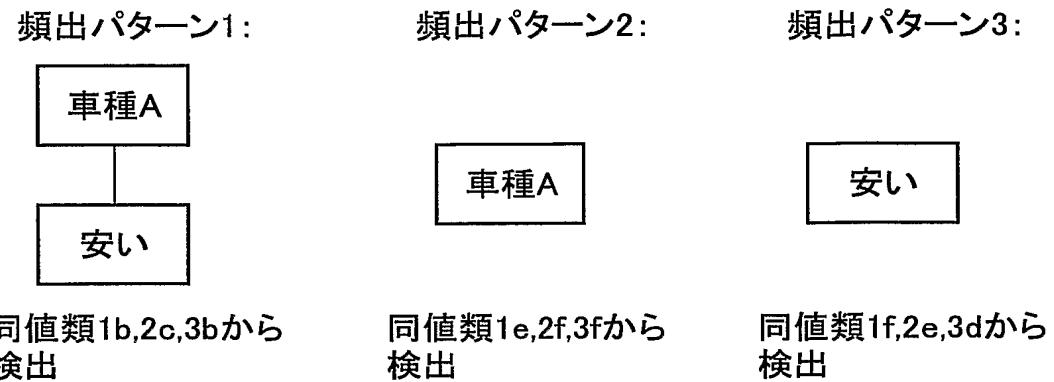


図 30

INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2005/005440

A. CLASSIFICATION OF SUBJECT MATTER
Int.Cl⁷ G06F17/30, 17/27, 19/00

According to International Patent Classification (IPC) or to both national classification and IPC

B. FIELDS SEARCHED

 Minimum documentation searched (classification system followed by classification symbols)
Int.Cl⁷ G06F17/30, 17/27, 19/00

 Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched
 Jitsuyo Shinan Koho 1922-1996 Jitsuyo Shinan Toroku Koho 1996-2005
 Kokai Jitsuyo Shinan Koho 1971-2005 Toroku Jitsuyo Shinan Koho 1994-2005

 Electronic data base consulted during the international search (name of data base and, where practicable, search terms used)
JSTPlus (JOIS)
C. DOCUMENTS CONSIDERED TO BE RELEVANT

| Category* | Citation of document, with indication, where appropriate, of the relevant passages | Relevant to claim No. |
|-----------|---|-----------------------|
| Y | JP 2001-134575 A (International Business Machines Corp.), 18 May, 2001 (18.05.01), Full text; Figs. 1 to 29 & US 6618725 B1 | 1-7, 12-18, 23, 24 |
| A | | 8-11, 19-22, 25 |
| Y | JP 10-198697 A (Fuji Xerox Co., Ltd.), 31 July, 1998 (31.07.98), Full text; Figs. 1 to 20 (Family: none) | 1-7, 12-18, 23, 24 |
| A | | 8-11, 19-22, 25 |
| A | JP 2000-76274 A (International Business Machines Corp.), 14 March, 2000 (14.03.00), Full text; Figs. 1 to 4 & US 6219664 B1 | 1-25 |

 Further documents are listed in the continuation of Box C.

 See patent family annex.

| | |
|---|--|
| * Special categories of cited documents: | |
| "A" document defining the general state of the art which is not considered to be of particular relevance | "T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention |
| "E" earlier application or patent but published on or after the international filing date | "X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone |
| "L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified) | "Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art |
| "O" document referring to an oral disclosure, use, exhibition or other means | "&" document member of the same patent family |
| "P" document published prior to the international filing date but later than the priority date claimed | |

 Date of the actual completion of the international search
 15 April, 2005 (15.04.05)

 Date of mailing of the international search report
 17 May, 2005 (17.05.05)

 Name and mailing address of the ISA/
 Japanese Patent Office

Authorized officer

Facsimile No.

Telephone No.

INTERNATIONAL SEARCH REPORT

International application No.

PCT/JP2005/005440

C (Continuation). DOCUMENTS CONSIDERED TO BE RELEVANT

| Category* | Citation of document, with indication, where appropriate, of the relevant passages | Relevant to claim No. |
|-----------|--|-----------------------|
| A | JP 4-218872 A (Fujitsu Ltd.), 10 August, 1992 (10.08.92), Full text; Figs. 1 to 16 & US 5345537 A | 1-25 |
| A | ASAI, T. et al., "Efficient Substructure Discovery from Large Semi-structured Data", Proc. of 2nd SIAM International Conf. on Data Mining, SDM2002, April 2002 [online]; [retrieved on 15 April, 2005 (15.04.05)] Retrieved from the Internet: <URL: http://www.siam.org/meetings/sdm02/proceedings/sdm02-10.pdf > | 1-25 |
| A | Taku KUDO et al., "Gengo Joho o Riyo shita Text Mining", Information Processing Society of Japan Kenkyu Hokoku, 2002-NL-148, 05 March, 2002 (05.03.02), Vol.2002, No.20, pages 65 to 72 | 1-25 |

A. 発明の属する分野の分類（国際特許分類（IPC））

Int.Cl.7 G06F17/30, 17/27, 19/00

B. 調査を行った分野

調査を行った最小限資料（国際特許分類（IPC））

Int.Cl.7 G06F17/30, 17/27, 19/00

最小限資料以外の資料で調査を行った分野に含まれるもの

| | |
|-------------|------------|
| 日本国実用新案公報 | 1922-1996年 |
| 日本国公開実用新案公報 | 1971-2005年 |
| 日本国実用新案登録公報 | 1996-2005年 |
| 日本国登録実用新案公報 | 1994-2005年 |

国際調査で使用した電子データベース（データベースの名称、調査に使用した用語）

JSTPlus(JOIS)

C. 関連すると認められる文献

| 引用文献の カテゴリー* | 引用文献名 及び一部の箇所が関連するときは、その関連する箇所の表示 | 関連する 請求の範囲の番号 |
|-----------------|---|-----------------------|
| Y | JP 2001-134575 A (インターナショナル・ビジネス・マシーンズ・コーポレーション) 2001.05.18, 全文、第1-29図 & US 6618725 | 1-7, 12-18, 23, 24 |
| A | B1 | 8-11, 19-22, 25 |
| Y | JP 10-198697 A (富士ゼロックス株式会社) 1998.07.31, 全文、第1-20図 (ファミリーなし) | 1-7, 12-18, 23, 24 |
| A | | 8-11, 19-22, 25 |

■ C欄の続きにも文献が列挙されている。

〔パテントファミリーに関する別紙を参照。〕

* 引用文献のカテゴリー

「A」特に関連のある文献ではなく、一般的技術水準を示すもの
 「E」国際出願日前の出願または特許であるが、国際出願日以後に公表されたもの
 「L」優先権主張に疑義を提起する文献又は他の文献の発行日若しくは他の特別な理由を確立するために引用する文献（理由を付す）
 「O」口頭による開示、使用、展示等に言及する文献
 「P」国際出願日前で、かつ優先権の主張の基礎となる出願

の日の後に公表された文献
 「T」国際出願日又は優先日後に公表された文献であって出願と矛盾するものではなく、発明の原理又は理論の理解のために引用するもの
 「X」特に関連のある文献であって、当該文献のみで発明の新規性又は進歩性がないと考えられるもの
 「Y」特に関連のある文献であって、当該文献と他の1以上の文献との、当業者にとって自明である組合せによって進歩性がないと考えられるもの
 「&」同一パテントファミリー文献

国際調査を完了した日

15. 04. 2005

国際調査報告の発送日

17. 5. 2005

国際調査機関の名称及びあて先

日本国特許庁 (ISA/JP)

郵便番号 100-8915

東京都千代田区霞が関三丁目4番3号

特許庁審査官（権限のある職員）

水野 恵雄

5M

3252

電話番号 03-3581-1101 内線 3597

| C (続き) . 関連すると認められる文献 | | 関連する 請求の範囲の番号 |
|-----------------------|---|------------------|
| 引用文献の カテゴリー* | 引用文献名 及び一部の箇所が関連するときは、その関連する箇所の表示 | |
| A | JP 2000-76274 A (インターナショナル・ビジネス・マシーンズ・コープレイション) 2000.03.14, 全文, 第1-4図 & US 6219664 B1 | 1-25 |
| A | JP 4-218872 A (富士通株式会社) 1992.08.10, 全文、第1-16図 & US 5345537 A | 1-25 |
| A | Asai, T. et al., 'Efficient Substructure Discovery from Large Semi-structured Data', Proc. of the 2nd SIAM International Conf. on Data Mining, SDM2002, April 2002 [online] ; [retrieved on 15 April 2005] Retrieved from the Internet: <URL: http://www.siam.org/meetings/sdm02/proceedings/sdm02-10.pdf > | 1-25 |
| A | 工藤拓、外3名、言語情報を利用したテキストマイニング、情報処理学会研究報告 2002-NL-148, 2002.03.05, 第2002巻, 第20号, p. 65-72 | 1-25 |